TECHNISCHE UNIVERSITÄT DRESDEN

# *"Analyse des Routenwahlverhaltens von Radfahrenden auf Grundlage GPS-basierter Daten zum real beobachteten Verkehrsverhalten"*

Dissertation

zur Erlangung des akademischen Grades

**Doktoringenieur**

(Dr.-Ing.)

Stefan Huber

Verteidigt am 16.03.2022

Erstgutachter: Prof. Dr.-Ing Udo J. Becker

Zweitgutachter: Prof.-Dr.-Ing. Christian Rudolph

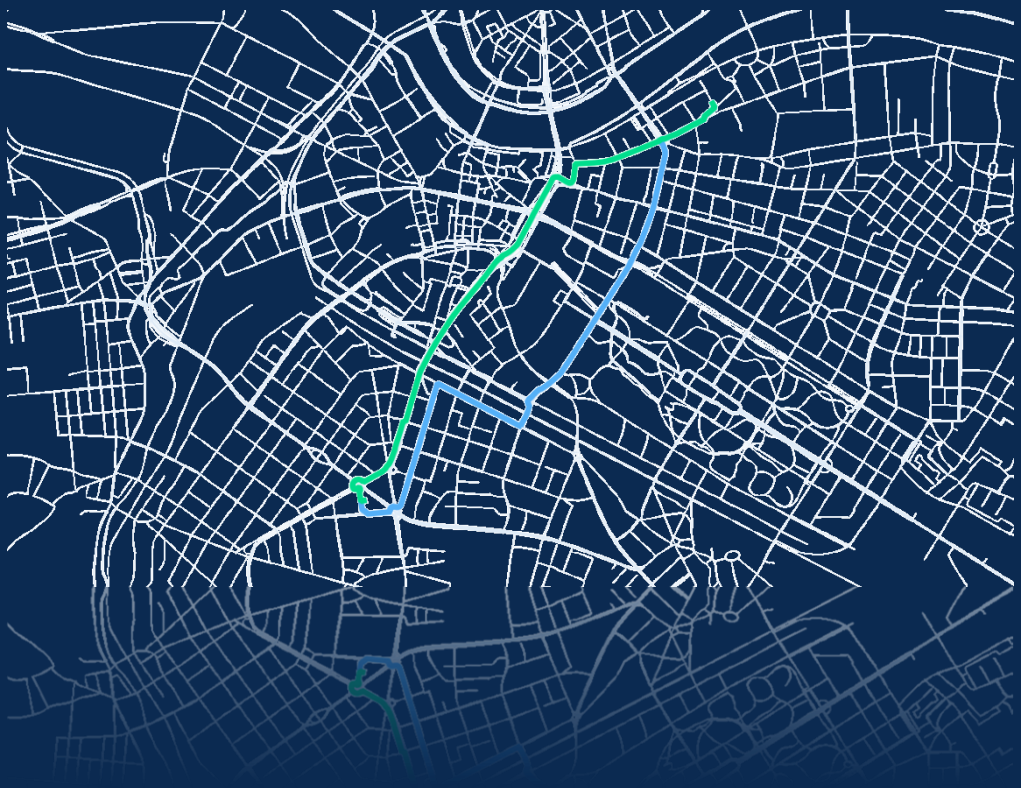

# Bibliografischer Nachweis

| | |
|---|---|
| Name, Vorname: | Huber, Stefan |
| Titel der Promotion: | Analyse des Routenwahlverhaltens von Radfahrenden auf Grundlage GPS-basierter Daten zum real beobachteten Verkehrsverhalten |
| Betreuende Einrichtung: | Technische Universität Dresden<br>Fakultät Verkehrswissenschaften „Friedrich List“<br>Institut für Verkehrsplanung und Straßenverkehr<br>Professur für Verkehrsökologie |

189 Seiten, 63 Abbildungen, 22 Tabellen, 45 Formeln

Anhang: 35 Abbildungen, 12 Formeln

# Autorenreferat

Eine an den Bedürfnissen von Radfahrer*innen orientierte Planung ist für die Förderung des Radverkehrs unumgänglich. Um den Ausbau der Radverkehrsinfrastruktur entsprechend zu planen, sind jedoch Informationen zum Routenwahlverhalten der Radfahrenden und dessen Einflussfaktoren notwendig. Mit diesen Informationen können z.B. Wirkungen von Maßnahmen oder die zukünftige Nutzung von geplanter Radverkehrsinfrastruktur abgeschätzt werden.

Aus diesem Grund wurden vor allem in der letzten Dekade zahlreiche internationale Arbeiten vorangetrieben, die die Routenwahl auf Basis von GPS-basierten Daten zum real beobachteten Routenwahlverhalten untersuchten. Da die Studien meist für einzelne und nichtdeutsche Städte durchgeführt wurden, lassen sich die Ergebnisse jedoch nicht direkt auf den deutschen Raum übertragen.

Um die Einflussfaktoren der Routenwahl für den deutschen Raum zu untersuchen, wird in dieser Arbeit die Routenwahl von Radfahrenden im Raum Dresden analysiert. Basis der Untersuchung stellt ein während der Aktion STADTRADELN erhobener GPS-Datensatz dar, der 18.459 Radfahrten von 1.361 Radfahrer*innen enthält und Auskunft über deren real beobachtetes Routenwahlverhalten gibt. Die erhobenen Routendaten wurden mit unterschiedlichen Verfahren aufbereitet und über ein Verkehrsnetz mit Sekundärdaten angereichert, sodass die Eigenschaften der gewählten Routen berechnet und den jeweils erzeugten und nicht gewählten Routenalternativen gegenübergestellt werden konnten. Der Einfluss der unterschiedlichen Faktoren wurde anschließend mittels logistischer Regressionsanalyse untersucht.

Das Ergebnis der Untersuchung zeigt auf, dass sich die folgenden Einflussfaktoren positiv auf die Routenwahl auswirken:

+ Existenz von Radverkehrsinfrastruktur
+ Geringe Längsneigungen
+ Gute Oberflächenbeschaffenheit (z.B. Asphalt)
+ Vorhandensein anderer Radfahrender entlang einer Route
+ Geringe zulässige Maximalgeschwindigkeit des motorisierten Verkehrs
+ Geringe Fahrstreifenanzahl des Kfz-Verkehrs
+ Durch Lichtsignalanlagen geregelte Knotenpunkte
+ Grün- und Wohngebietsflächen

Demgegenüber üben die folgenden Einflussfaktoren einen negativen Einfluss auf die Wahl einer Route aus:

- Zunehmende Distanz
- Hohe Streckenanteile mit großer Längsneigung
- Eine hohe maximale Längsneigung der Route
- Geringe Breite der Radverkehrsführung
- Höhere Unfallhäufigkeit entlang der Route

Für einige Einflussfaktoren konnte kein (signifikanter) Einfluss auf die Routenwahl nachgewiesen werden. Dazu gehören bspw. die durchschnittlich tägliche Verkehrsstärke des Kfz-Verkehrs, der ruhende Verkehr oder die Häufigkeit von „rechts-vor-links" geregelten Knotenpunkten.

Die vorliegende Arbeit konnte dazu beitragen, die Wirkung der Einflussfaktoren auf die Routenwahl im Radverkehr einer deutschen Stadt zu quantifizieren. Eine Stärke der Untersuchung liegt in der Erhebung und Nutzung des umfangreichen GPS-Datensatzes zum real beobachteten Routenwahlverhalten der Radfahrer*innen. Das resultierende Routenwahlmodell kann für die Abschätzung von Maßnahmenwirkungen genutzt werden (z.B. im Rahmen der Verkehrsnachfragemodellierung).

Eine kritische Reflexion der Ergebnisse und Methoden zeigt, dass die Qualität der Analyse und ihrer Ergebnisse durch die Nutzung weiterer Sekundär- und Primärdaten sowie anderer Methoden weiter verbessert werden kann.

Die Ergebnisse der Untersuchung geben einen Einblick in die Routenwahl der Radfahrenden des Untersuchungsgebiets. Im Rahmen der Arbeit konnte nicht geprüft werden, ob die Routenwahl der Radfahrer*innen in Dresden vergleichbar mit der Routenwahl in anderen deutschen Städten ist. Das entwickelte Verfahren kann jedoch auch für Analysen in anderen Städten angewendet werden, sodass verlässliche Aussagen zur Routenwahl deutscher Radfahrender in anderen deutschen Kommunen erarbeitet werden können.

Es lassen sich insgesamt folgende Schlussfolgerungen ziehen: Um den Radfahrenden eine möglichst attraktive Radverkehrsinfrastruktur zu bieten und damit die Nutzung des Fahrrads zu fördern, sollte der Radverkehr auf eigener Radverkehrsinfrastruktur geführt werden, die möglichst breit ist und eine gute Oberflächenqualität besitzt. Entlang der Radrouten sollten die Geschwindigkeiten des fließenden motorisierten Verkehrs möglichst reduziert werden. Die Bündelung von Radverkehrsströmen sowie die Führung durch Grünflächen kann zudem Fahrtkomfort und Sicherheitsempfinden erhöhen.

# Executive Summary

User-oriented bicycle planning is essential for the promotion of cycling in cities. In order to adequately plan and build cycling infrastructure, information on route choice behaviour of cyclists and its influencing factors is essential. The knowledge about influencing factors of bicycle route choice can help to assess the effect of measures as well as future or potential utilisation of planned cycling infrastructure.

Several international studies – particularly carried out in the last decade – examined route choice based on GPS-based revealed preference data. As the studies were mostly conducted for few and non-German cities the results, however, cannot be directly transferred to the German area.

In order to investigate bicycle route choice for the German area, the route choice of cyclists in the city of Dresden is analysed in this study. The basis of the investigation is a GPS data set collected during the CITY CYCLING campaign. It contains 18,459 bicycle trips by 1,361 cyclists and provides detailed information about the observed route choice behaviour of cyclists. The collected route data were processed by using different methods. Linking the routes to a traffic supply network allowed enriching them with secondary data so that characteristics of the selected routes and the non-selected generated alternatives were determined. The influence of the different factors was investigated using logistic regression analysis.

The results of the study reveal that the following influencing factors positively affect bicycle route choice:

+ Existence of cycling infrastructure
+ Low slopes
+ Good surface conditions (e.g. asphalt)
+ Presence of other cyclists along a route
+ Low maximum speed of motorised traffic
+ Few number of lanes for motorised traffic
+ Intersections controlled by traffic signals
+ Green and residential areas

In contrast, the following factors show a negative influence on bicycle route choice:

– Increasing distance
– High proportion of routes with steep longitudinal gradients
– A high maximum gradient along the route
– Narrow width of the cycle lane
– Higher accident frequency along the route

For some influencing factors, no (significant) influence on route choice was found (e.g. for the average daily traffic volume of motorized traffic, stationary traffic or the frequency of right-of-way regulated intersections).

The present study contributes to the quantification of influencing factors or rather their effect on bicycle route choice in a German city. Furthermore, the resulting route choice model can be used to estimate the effects of different measures (e.g. in the context of traffic demand modelling). A strength of the study is the extensive data set on revealed preferences of cyclists that has been used to analyse route choice behaviour.

A critical reflection of the results and methods shows that the quality of the analysis and its results could further be improved by using more secondary and primary data as well as other models for analysis.

The results of the study provide an insight into route choices of cyclists in the study area. However, it could not be determined whether route choice of cyclists in Dresden is similar to route choice of cyclists in other German cities. Nevertheless, the developed method could also be used to analyse route choice in other cities, so that reliable statements on route choice of German cyclists can be compiled.

Overall, the following conclusions can be drawn: in order to provide cyclists the most attractive cycling infrastructure possible and, thus, promote the use of cycling in cities, bicycle traffic should be guided on dedicated and wide cycling infrastructure with good surface quality. Furthermore, the speed of moving motorised traffic should be reduced along the route segments if possible. Bundling of cycling traffic flows and routing cyclists through green spaces can furthermore increase riding comfort and the perception of safety.

# Danksagung

An dieser Stelle möchte ich gern zahlreichen Menschen, zu denen ich in fachlicher und persönlicher Beziehung stehe, meinen Dank aussprechen.

Zunächst möchte ich meinem Betreuer und Gutachter Prof. Dr-Ing. Udo J. Becker einen herzlichen Dank aussprechen. Aufgrund seiner fachlichen Begleitung, vor allem aber mit seiner einzigarten und unnachahmlichen Art der menschlichen Führung, seiner Offenheit und seinem Rat, sowie dank seiner Ermutigungen und seinem stets zielgerichteten und konstruktiven Feedback habe ich mich an der Professur für Verkehrsökologie immer gut aufgehoben gefühlt. Ein besseres Umfeld für die Durchführung dieser Arbeit hätte ich mir nicht wünschen können.

Ein großer Dank gilt zudem den Kollegen und Kolleginnen aus den unterschiedlichen Forschungsprojekten, an denen ich im Rahmen meiner Tätigkeit am Lehrstuhl mitwirken konnte. Paul Lindemann gilt ein besonderer Dank für die Umsetzung und Programmierung von Konzepten und Algorithmen, die für diese Arbeit eine wichtige Grundlage darstellten. Darüber hinaus gilt ein Dank allen anderen Mitarbeitenden (dies schließt explizit auch studentische Hilfskräfte ein), die im Rahmen des Projekts „Sichere Routenwahl“ insbesondere an der Erhebung und Aufbereitung der Sekundärdaten mitgewirkt haben, die ebenfalls eine Basis der vorliegenden Arbeit darstellen.

Einen aufrichtigen Dank möchte ich zudem Sven Lißner aussprechen, der mir in den vergangenen Jahren immer mit fachlicher Expertise und konstruktiven Diskussionen zur Seite stand, die stets eine Bereicherung für mich darstellten. Ich bin dankbar dafür, dass er in den vergangenen Jahren nicht nur ein geschätzter Kollege geworden ist, sondern auch ein sehr guter Freund.

Nicht zuletzt gilt ein Dank auch all jenen Kolleginnen und Kollegen, die hier nicht explizit erwähnt wurden und die dennoch immer ein offenes Ohr und Zeit für Diskussionen bzw. einen fachlichen Austausch hatten.

Ein letzter und nicht mindergroßer Dank gilt meiner Freundin Angélique Hoyer, die meinen Aufenthalt in Dresden stets mitgetragen und mir in allen Facetten die Unterstützung gegeben hat, die ich für die Durchführung der Arbeit gebraucht habe.

# Gender-Disclaimer

Sprache ist ein wichtiger und lebendiger Teil unserer gesellschaftlichen Wirklichkeit. Sie befindet sich in stetem Wandel und kann, wird und sollte zu Gleichstellungszwecken modifiziert werden. Aus diesem Grund wird in der vorliegenden Arbeit auf das generische Maskulinum verzichtet. Stattdessen wurden geschlechtergerechte Formulierungen gewählt. Zitate bleiben davon jedoch unberührt und wurden demnach, so sie keine geschlechtergerechte Sprache enthalten, nicht angepasst.

# Inhaltsverzeichnis

**BIBLIOGRAFISCHER NACHWEIS** ..... III

**AUTORENREFERAT** ..... IV

**EXECUTIVE SUMMARY** ..... VI

**DANKSAGUNG** ..... VIII

**GENDER-DISCLAIMER** ..... IX

**INHALTSVERZEICHNIS** ..... XI

**ABBILDUNGSVERZEICHNIS** ..... XIII

**TABELLENVERZEICHNIS** ..... XVII

**FORMELVERZEICHNIS** ..... XVIII

**ABKÜRZUNGSVERZEICHNIS** ..... XX

**1. EINLEITUNG** ..... 1

1.1 AUSGANGSSITUATION ..... 1
1.2 PROBLEMSTELLUNG ..... 2
1.3 FRAGESTELLUNG ..... 3
1.4 AUFBAU DER ARBEIT ..... 4

**2. GRUNDLAGEN** ..... 6

2.1 RADVERKEHR IN DEUTSCHLAND ..... 6
*2.1.1 Bedeutung und Eigenschaften* ..... *6*
*2.1.2 Vorteile und Potentiale des Radverkehrs* ..... *9*
*2.1.3 Radverkehrsförderung und -planung* ..... *12*
2.2 ANALYSE UND MODELLIERUNG VON ENTSCHEIDUNGEN ..... 14
*2.2.1 Diskrete Wahltheorie* ..... *15*
*2.2.2 Multiple logistische Regressionsanalyse* ..... *16*
*2.2.3 Verkehrsangebot und Verkehrsnachfrage* ..... *21*
*2.2.4 Routensuchverfahren* ..... *24*
2.3 GPS-DATEN ZUM RADVERKEHR ..... 26
*2.3.1 Global Positioning System – GPS* ..... *27*
*2.3.2 Nutzen von GPS-Daten für die Radverkehrsplanung und -forschung* ..... *29*
2.4 ZUSAMMENFASSUNG ..... 33

**3. FORSCHUNGSSTAND** ..... 34

3.1 METHODIK DER LITERATURRECHERCHE ..... 34
3.2 ANALYSE DER ROUTENWAHL MITTELS MULTIVARIATER STATISTISCHER VERFAHREN ..... 37
3.3 ZUSAMMENFASSUNG DER RECHERCHE ..... 51

**4. METHODISCHES VORGEHEN** ..... 53

4.1 UNTERSUCHUNGSRAUM – DRESDEN ..... 53
*4.1.1 Allgemeine geographische Einordnung* ..... *53*
*4.1.2 Verkehrssituation* ..... *54*

4.2 DATEN ... 59
*4.2.1 Primärdatenerhebung und -aufbereitung ... 59*
4.2.1.1 Datenerhebung ... 60
4.2.1.2 Datenaufbereitung ... 63
*4.2.2 Sekundärdatenaufbereitung ... 66*
*4.2.3 Netzmodell ... 80*
*4.2.4 Map Matching ... 81*
*4.2.5 Erzeugung von Alternativrouten ... 84*
*4.2.6 Attribuierung der Routen/-alternativen ... 88*
*4.2.7 Zusammenfassung der Datenaufbereitung ... 96*
4.3 ROUTENWAHLMODELL ... 98
*4.3.1 Diskretes Wahlmodell ... 98*
*4.3.2 Bestimmung der Modell-Güte ... 107*
4.4 ZUSAMMENFASSUNG UND ABLAUFBESCHREIBUNG ... 114

**5. ERGEBNISSE ... 116**

5.1 DESKRIPTIVE STATISTIK ... 116
5.2 MULTIPLE LOGISTISCHE REGRESSIONSANALYSE ... 140
*5.2.1 Einflussfaktoren der Routenwahl ... 140*
*5.2.2 Modell-Güte ... 152*
5.3 ZUSAMMENFASSUNG ... 156

**6. DISKUSSION ... 159**

6.1 INTERPRETATION DER ERGEBNISSE UND EINORDNUNG IN DEN FORSCHUNGSKONTEXT ... 159
6.2 KRITISCHE REFLEXION DER GENUTZTEN DATEN UND METHODEN ... 169
*6.2.1 Primärdaten ... 169*
*6.2.2 Sekundärdaten ... 177*
*6.2.3 Methoden ... 180*
6.3 ZUSAMMENFASSUNG ... 185

**7. FAZIT UND AUSBLICK ... 187**

**LITERATURVERZEICHNIS ... 191**

**ANHANG ... 203**

ANHANG 1 ... 203
ANHANG 2 ... 204
ANHANG 3 ... 221
ANHANG 4 ... 222
ANHANG 5 ... 223
ANHANG 6 ... 230
ANHANG 7 ... 231
ANHANG 8 ... 233

# Abbildungsverzeichnis

Abbildung 1: Vorgehen im Rahmen der vorliegenden Arbeit ..... 5

Abbildung 2: Entwicklung des Verkehrsaufkommens in Deutschland (Eigene Darstellung nach Nobis 2019) ..... 7

Abbildung 3: Vergleich der Reisezeiten unterschiedlicher Verkehrsmittel im Stadtverkehr von „Tür-zu-Tür“ (Eigene Darstellung nach UBA 2019) ..... 10

Abbildung 4: Ablauf der zielorientierten Verkehrsplanung (Eigene Darstellung nach FGSV 2018) . 13

Abbildung 5: Lineare und logistische Funktion (Eigene Darstellung nach Backhaus, et al. 2016) ... 18

Abbildung 6: Die vier Stufen der Verkehrsnachfragmodellierung (links die Stufe; rechts das Ergebnis) ..... 23

Abbildung 7: Beispiel zur Erläuterung der IIA-Eigenschaft (Eigene Darstellung nach Schnabel und Lohse 2011) ..... 26

Abbildung 8: Prinzip der Positionsbestimmung mittels GNSS (Eigene Darstellung nach NASA 2008) ..... 28

Abbildung 9: Übersicht der genutzten Literaturdatenbanken und Anzahl der recherchierten Studien ..... 36

Abbildung 10: Überblick über das methodische Vorgehen ..... 53

Abbildung 11: Entwicklung des Modal Split für Dresden (Eigene Darstellung nach LH-Dresden-d 2020) ..... 54

Abbildung 12: Modal Split in Dresden 2018 nach Altersgruppen (Eigene Darstellung nach LH-Dresden-d 2020) ..... 55

Abbildung 13: Modal Split in Dresden 2018 nach Entfernungsklassen (Eigene Darstellung nach LH-Dresden-d 2020) ..... 56

Abbildung 14: Modal Split in Dresden 2018 nach Wegezwecken (Eigene Darstellung nach LH-Dresden-d 2020) ..... 56

Abbildung 15: Radverkehrsmengen in Dresden im Jahr 2015/16 (Quelle: Lißner, Francke und Becker 2017) ..... 58

Abbildung 16: Überblick über Primärdatenerhebung und -aufbereitung ..... 60

Abbildung 17: Die STADTRADELN-App ..... 61

Abbildung 18: Schritte der Primärdatenaufbereitung ..... 64

Abbildung 19: Punkte einer aufgezeichneten Fahrt (blau) inkl. Zwischenhalt (grün) an einem Aktivitäten-Ort ..... 65

Abbildung 20: Vereinfachte Veranschaulichung der Entscheidungsprozesse zur Erkennung von Radfahrten im GPS-Datensatz ..... 66

Abbildung 21: Darstellung des Netzmodells für den Dresdner Raum ..... 81

Abbildung 22: Ungenaue Lage von GPS-Punkten bedingt durch Messungenauigkeiten ..... 82

Abbildung 23: Reduzierter GPS-Track ..... 82

Abbildung 24: Suche von Knotenpunktkandidaten im Netz ..... 83

Abbildung 25: Ergebnis des Map Matching – die gematchte Route im Netz ..... 83

Abbildung 26: Gewählte Route (blau) und erzeugte Routenalterativen (grün, braun) (Darstellung: Lindemann) ..... 86

Abbildung 27: Pufferbildung ab Verkürzungslänge O (Darstellung: Lindemann) ..... 87

Abbildung 28: Überblick über die Datenverarbeitung ausgehend von den aufbereiteten Radfahrten ..... 96

Abbildung 29: Korrelationsmatrix der unabhängigen Variablen. Dargestellt ist der Korrelationskoeffizient nach Bravais-Pearson $r_{BP}$ ..... 104

Abbildung 30: Ablaufschema der Methode ..... 115

Abbildung 31: Geschlechterverteilung innerhalb der Stichprobe (n = 1.361) ..... 117

Abbildung 32: Altersverteilung innerhalb der Stichprobe (n = 1.347) ..... 117

Abbildung 33: Netzabdeckung der Radfahrten in Dresden ..... 118

Abbildung 34: Boxplot (links) und Histogramm (rechts) der Fahrtweiten ..... 119

Abbildung 35: Verteilung der Fahrtweiten und Fahrtdauer ..... 120

Abbildung 36: Boxplot (links) und Histogramm (rechts) der Fahrtweiten der Routen und ihrer Alternativen ..... 122

Abbildung 37: Boxplot (links) und Verteilung (rechts) der max. Längsneigung der Routen und Alternativen ..... 123

Abbildung 38: Durchschnittliche Anteile der Längsneigungsklassen entlang der Routen und Alternativen ..... 124

Abbildung 39: Durchschnittliche Anteile der Führungsform der Routen und Alternativen ..... 125

Abbildung 40: Verteilung der Anteile mit (links) und ohne (rechts) Radverkehrsinfrastruktur entlang der Routen und Alternativen ..... 125

Abbildung 41: Durchschnittliche Anteile der Breite der Radverkehrsführung (RVF) entlang der Routen und Alternativen ..... 126

Abbildung 42: Verteilung der Breite der Radverkehrsführung (RVF) entlang der Routen und Alternativen ..... 127

Abbildung 43: Verteilung der Oberflächentypen „Asphalt“ und „Kopfsteinpflaster“ entlang der Routen und Alternativen ..... 128

Abbildung 44: Durchschnittliche Anteile der Oberflächentypen entlang der Routen und Alternativen ..... 128

Abbildung 45: Durchschnittlich tägliche Radverkehrsstärke (DTV-Rad) entlang der Routen und Alternativen ..... 129

Abbildung 46: Durchschnittliche Anteile der Radverkehrsstärken-Klassen entlang der Routen und Alternativen ..... 130

Abbildung 47: $DTV_{Kfz}$ entlang der Routen und deren Alternativen ..... 130

Abbildung 48: Verteilung der Fahrstreifenanzahl (FS) entlang der Routen und Alternativen ..... 131

Abbildung 49: Durchschnittliche Anteile der Fahrstreifenanzahl (FS) entlang der Routen und Alternativen ..... 132

Abbildung 50: Verteilung der Anteile der max. zulässigen Geschwindigkeit ($v_{max}$) des MV entlang der Routen und Alternativen ..... 133

Abbildung 51: Durchschnittliche Streckenanteile der max. zulässigen Geschwindigkeit ($v_{max}$) des MV entlang der Routen und Alternativen ..... 133

Abbildung 52: Durchschnittliche Anteile der Anordnungsformen des ruhenden Verkehrs entlang der Routen und Alternativen ..... 134

Abbildung 53: Verteilung der Anordnungsformen des ruhenden Verkehrs entlang der Routen und Alternativen ..... 135

Abbildung 54: Verteilung der Unfallhäufigkeit und Häufigkeit von Punkten kritischer Situationen entlang der Routen und Alternativen ..... 136

Abbildung 55: Verteilung der Regelungsarten an Knotenpunkten entlang der Routen und Alternativen ..... 138

Abbildung 56: Durchschnittliche Anteile der Flächennutzungstypen entlang der Routen und Alternativen ..... 138

Abbildung 57: Verteilung der Wohn- und Grünflächenanteile entlang der Routen und Alternativen ..... 139

Abbildung 58: Anzahl der Radfahrenden im Vergleich ..... 169

Abbildung 59: Altersverteilung der Stichproben im Vergleich ..... 170

Abbildung 60: Geschlechterverteilung der Stichproben im Vergleich ..... 171

Abbildung 61: Fahrtenanzahl im Vergleich mit SrV 2018 ..... 173

Abbildung 62: Gesamtstrecke im Vergleich mit SrV 2018 ..... 173

Abbildung 63: Fahrtweitenverteilung im Vergleich ..... 174

Abbildung 64: Radverkehrsnetz von Dresden inkl. der Führungsformen (Quelle: LH-Dresden-f 2017) ..... 203

Abbildung 65: Schritte der Primärdatenaufbereitung ..... 204

Abbildung 66: Verteilung der Accuracy der GPS-Punkte im Datensatz ..... 205

Abbildung 67: Perzentile der Distanzen zwischen den GPS-Punkten ..... 207

Abbildung 68: Vergleich des Geschwindigkeitsverlauf von nicht geglätteter und geglätteter Geschwindigkeit ..... 208

Abbildung 69: Punkte einer aufgezeichneten Fahrt (blau) inkl. Zwischenhalt an einem Aktivitäten-Ort (grün) ..... 210

Abbildung 70: Vereinfachte Veranschaulichung der Entscheidungsprozesse zur Erkennung von Radfahrten im GPS-Datensatz ..... 211

Abbildung 71: Beispielhafte Darstellung der Unterschiede in der Geschwindigkeitsver- teilung von Fahrten und Aktivitäten ..... 212

Abbildung 72: Beispielhafte Darstellung der Unterschiede in der Distanzverteilung von Fahrten und Aktivitäten ..... 212

Abbildung 73: Beispielhafte Darstellung der Änderung der Richtungsvektoren bei einer Fahrt (a) und einer Aktivität (b) ..... 212

Abbildung 74: Beispielhafte Darstellung der Verteilung der Änderung der Richtungsvektoren bei Radfahrten und Aktivitäten ..... 212
Abbildung 75: Darstellung von Geschwindigkeit, Richtungsvektoränderung, Distanz und TAU .. 215
Abbildung 76: Mittlere Geschwindigkeitsverteilung unterschiedlicher Verkehrsmittel ..... 216
Abbildung 77: Boxplot-Diagramm der mittleren Geschwindigkeiten der Verkehrsmittel ..... 216
Abbildung 78: Boxplot-Diagramm der mittleren Beschleunigung unterschiedlicher Verkehrsmittel ..... 216
Abbildung 79: Boxplot-Diagramm der Umwege-Faktoren unterschiedlicher Verkehrsmittel ..... 216
Abbildung 80: Entscheidungsbaum der Verkehrsmittelerkennung ..... 218
Abbildung 81: Gegenüberstellung von Verkehrsstärken aus den Referenz- und den GPS-Daten 221
Abbildung 82: Aggregation der Flächennutzungsklassen ..... 222
Abbildung 83: Verteilung der Radverkehrsführungsform ..... 223
Abbildung 84: Verteilung der Breite der Radverkehrsführungsform ..... 223
Abbildung 85: Verteilung der Oberflächenbeschaffenheit ..... 224
Abbildung 86: Verteilung der Radverkehrsstärken ..... 224
Abbildung 87: Verteilung der Kfz-Verkehrsstärken ..... 225
Abbildung 88: Verteilung der Anzahl der Fahrstreifenanzahl ..... 225
Abbildung 89: Verteilung der maximal zulässigen Geschwindigkeit des Kfz-Verkehrs ..... 226
Abbildung 90: Verteilung des ruhenden Verkehrs ..... 226
Abbildung 91: Verteilung Sicherheitsraum ..... 227
Abbildung 92: Verteilung objektiven und subjektiven Sicherheit an Strecken ..... 228
Abbildung 93: Verteilung objektiven und subjektiven Sicherheit an Knotenpunkten ..... 228
Abbildung 94: Verteilung der Knotenpunkte und ihrer Regelungsart ..... 229
Abbildung 95: Verteilung objektiven und subjektiven Sicherheit an Knotenpunkten ..... 229
Abbildung 96: Aggregationsschlüssel der unabhängigen Variablen ..... 230
Abbildung 97: Korrelationsmatrix der unabhängigen Variablen (Teil 1) ..... 231
Abbildung 98: Korrelationsmatrix der unabhängigen Variablen (Teil 2) ..... 232
Abbildung 99: Chi-Quadrat-Tabelle ..... 233

# Tabellenverzeichnis

Tabelle 1: GNSS-Segmente und ihre Eigenschaften (Eigene Darstellung nach NASA 2008 und NASA 2017) ..... 27

Tabelle 2: Stärken und Schwächen der unterschiedlichen GPS-basierten Daten ..... 31

Tabelle 3: Übersicht über Studien zur Routenwahl ..... 38

Tabelle 4: Von der Aufzeichnungskomponente der App übermittelte Daten ..... 62

Tabelle 5: In die Analyse aufgenommene Prädiktor-Variablen ..... 105

Tabelle 6: Confusion Matrix zur Gegenüberstellung der beobachteten und der vorhergesagten Werte. Richtige Vorhersagen sind in Grün, falsche in Blau hinterlegt. (Eigene Darstellung nach Powers 2007) ..... 111

Tabelle 7: Kennwerte der Fahrtweiten ..... 119

Tabelle 8: Kennwerte der Fahrtdauer ..... 120

Tabelle 9: Kennwerte der Geschwindigkeiten ..... 121

Tabelle 10: Kennwerte der Fahrtweiten der Routen und ihrer Alternativen ..... 122

Tabelle 11: Kennwerte zur max. Längsneigung der Routen und ihrer Alternativen ..... 124

Tabelle 12: Kennwerte der mittleren Kraftfahrzeugverkehrsstärke entlang der Routen und Alternativen ..... 130

Tabelle 13: Kennwerte zur Unfallhäufigkeit und Punkte kritischer Situationen entlang der Routen und Alternativen ..... 136

Tabelle 14: Kennwerte zur Regelung an Knotenunkten entlang der Routen und Alternativen ..... 137

Tabelle 15: Ergebnisse der logistischen Regressionsanalyse ..... 141

Tabelle 16: Confusion Matrix zum vorliegenden Modell ..... 153

Tabelle 17: Confusion Matrix zur Prognose der Wahl im RadVerS-Datensatz ..... 155

Tabelle 18: Überblick über den Einfluss der einzelnen Variablen (von stark positiv +++ bis stark negativ – – –; o - kein Einfluss). ..... 157

Tabelle 19: Vergleich der Primärdaten ..... 170

Tabelle 20: Kennwerte der Geschwindigkeiten im Vergleich ..... 174

Tabelle 21: Vergleich der Primärdaten (k.A. – keine Angabe) ..... 176

Tabelle 22: Zusammenfassung der Stärken, Schwächen, Chancen und Risiken des Verfahrens 185

# Formelverzeichnis

(1) ..... 16
(2) ..... 16
(3) ..... 16
(4) ..... 17
(5) ..... 17
(6) ..... 17
(7) ..... 18
(8) ..... 18
(9) ..... 19
(10) ..... 26
(11) ..... 68
(12) ..... 68
(13) ..... 68
(14) ..... 69
(15) ..... 89
(16) ..... 89
(17) ..... 90
(18) ..... 90
(19) ..... 90
(20) ..... 91
(21) ..... 91
(22) ..... 92
(23) ..... 92
(24) ..... 93
(25) ..... 93
(26) ..... 93
(27) ..... 94
(28) ..... 94
(29) ..... 94
(30) ..... 95
(31) ..... 95
(32) ..... 102
(33) ..... 107

(34) ..... 108
(35) ..... 108
(36) ..... 109
(37) ..... 110
(38) ..... 110
(39) ..... 110
(40) ..... 111
(41) ..... 112
(42) ..... 112
(43) ..... 112
(44) ..... 112
(45) ..... 172
(46) ..... 208
(47) ..... 208
(48) ..... 208
(49) ..... 209
(50) ..... 209
(51) ..... 213
(52) ..... 213
(53) ..... 214
(54) ..... 214
(55) ..... 214
(56) ..... 214
(57) ..... 217
(58) ..... 217

# Abkürzungsverzeichnis

| | |
|---|---|
| BMVI | Bundesministerium für Verkehr und digitale Infrastruktur |
| BNL | Binomial Logit |
| DGM | Digitales Geländemodell |
| DTV | Durchschnittliche tägliche Verkehrsstärke |
| EBK | Erweiterte Blockkarte |
| ERA | Empfehlungen für Radverkehrsanlagen |
| EUSKa | Europäischen Unfalltypensteckkarte |
| EVE | Empfehlungen für Verkehrserhebungen |
| FS | Fahrstreifen |
| GEV | Generalized Extreme Value |
| GNSS | Global Navigation Satellite Systems |
| GPS | Global Positioning System |
| ID | Identifikator |
| IIA | Independence of Irrelevant Alternatives |
| Kfz | Kraftfahrzeug |
| KI | Künstliche Intelligenz |
| LL | Log-Likelihood |
| LLR | Likelihood-Ratio |
| LSA | Lichtsignalanlagen |
| LSE | Least Squares Errors |
| MIV | Motorisierter Individualverkehr |
| MV | Motorisierter Verkehr |
| MLE | Maximum-Likelihood Estimation |
| MNL | Multinomial Logit |
| OLS | Ordinary Least Square |
| ÖPNV | Öffentlichen Personennahverkehr |
| ÖPV | Öffentlichen Personenverkehr |
| OR | Odds Ratio |
| OSM | OpenStreetMap |
| Pkm | Personenkilometer |
| PSL | Path Size Logit |

| | |
|---|---|
| QZR | Quelle-Ziel-Relation |
| RiLSA | Richtlinien für Lichtsignalanlagen |
| RP | Revealed Preference |
| RVF | Radverkehrsführungsform |
| SP | Stated Preference |
| SRTM | Shuttle Radar Topography Mission |
| SrV | System repräsentativer Verkehrsbefragungen |
| STA | Straßentiefbauamt |
| STP | Stichprobe |
| TNR | True negatives rate |
| TPR | True positives rate |
| TRID | Transportation Research Information Database |
| TUD | Technische Universität Dresden |
| UBA | Umweltbundesamt |
| VCD | Verkehrsclub Deutschland |

# 1. Einleitung

## 1.1 Ausgangssituation

In der Diskussion um die Vermeidung negativer Auswirkungen des städtischen Verkehrs auf Mensch und Umwelt rückte in der jüngeren Vergangenheit ein Verkehrsmittel zunehmend in den Fokus der Debatte: das Fahrrad. Dem Fahrrad wird großes Potential für das Erreichen eines umweltfreundlicheren Verkehrssystems zugesprochen (UBA 2013). Dies begründet sich vor allem darin, dass sich Radfahren mit Muskelkraft und ohne den Einsatz fossiler Energieträger realisieren lässt. Durch die Verlagerung von Alltagsfahrten bspw. vom motorisierten Individualverkehr (MIV) auf den Radverkehr könnten negative verkehrliche Wirkungen (z.B. Lärm- und Schadstoffemissionen) signifikant reduziert werden (UBA 2019).

Die Ergebnisse von Haushaltsbefragungen zeigen, dass die Beliebtheit des Verkehrsmittels Fahrrad weiter steigt (SINUS 2019) und dass der Trend zur häufigeren Nutzung des Fahrrads deutschlandweit anhält (Nobis 2019). Um diese positive Entwicklung zu fördern, müssen möglichst günstige Rahmenbedingungen für die Radfahrenden geschaffen werden, denn ein Schlüsselfaktor dazu ist eine gut ausgebaute und an den Bedürfnissen der Radfahrer*innen orientierte Radverkehrsinfrastruktur (Thiemann-Linden und Mettenberger 2011).

Aufgrund der häufig knappen personellen und vor allem finanziellen Ressourcen, die für die Umsetzung von Maßnahmen (z.B. Neu- oder Umbau von Radverkehrsinfrastruktur) eingesetzt werden können, ist in vielen deutschen Kommunen jedoch meist keine breite Angebotsplanung möglich (VCD 2019). Daher werden im Rahmen der Radverkehrsplanung Informationen benötigt, auf deren Grundlage die Verkehrsplaner*innen Entscheidungen treffen und den Mitteleinsatz priorisieren können. Eine wesentliche Information ist dabei jene über die Routenwahl von Radfahrenden (Friedrich, et al. 2011). Sie kann helfen entscheidende Faktoren der Routenwahl und damit auch der Fahrradnutzung insgesamt zu beleuchten und ist gleichzeitig ein wichtiger Input für Verkehrsmodelle, die im Planungsprozess häufig zum Einsatz kommen. Mit ihrer Hilfe kann die Routenwahl von Radfahrenden modelliert und so die Wirkung von Maßnahmen abgeschätzt werden (Köhler 2014).

Um die Wirkung von Maßnahmen abschätzen und die Routenwahl realitätsnah modellieren zu können, muss zunächst jedoch die Wirkung unterschiedlicher Einflussfaktoren auf die Routenwahl analysiert werden.

## 1.2 Problemstellung

In der jüngeren Vergangenheit wurden zahlreiche Forschungsarbeiten zur Analyse der Routenwahl durchgeführt. Die meisten Studien basieren auf sog. *Stated Preference*-Experimenten (SP), in denen Präferenzen von Radfahrer*innen selbst angegeben werden. SP-Experimente eignen sich gut, um Präferenzen von Proband*innen zu analysieren, die sich in der Realität aber oft schwer verifizieren lassen (z.B. aufgrund fehlender Daten oder begrenzter Rechenkapazitäten). Zudem lassen sich einzelne Einflussfaktoren in SP-Experimenten leicht separieren und auch der Einfluss von nichtexistierenden Faktoren abschätzen (Hood, Sall und Charlton 2011).

Durch die Nutzung von SP-Experimenten konnten bereits zahlreiche Erkenntnisse zur Routenwahl gewonnen werden (siehe bspw. Lott, Tardiff und Lott 1978; Aultman-Hall, Hall und Baetz 1997; Segadilha und Sanches 2014; Larsen und El-Geneidy 2011; Stinson und Bhat 2005; Sener, Eluru und Bhat 2009). Die Ergebnisse dieser Arbeiten unterscheiden sich geringfügig und es kann insgesamt konstatiert werden, dass Radfahrende kürzere Routen mit weniger starken Anstiegen (Längsneigungen) bevorzugen und dass ein Vorhandensein geeigneter Radverkehrsinfrastruktur, ein geringes Verkehrsaufkommen des MIV sowie geringe Geschwindigkeiten des fließenden motorisierten Verkehrs die Auswahlwahrscheinlichkeit einer Route positiv beeinflussen. Eine möglichst geringe Anzahl an Knotenpunkten und Lichtsignalanlagen entlang der Route wirken sich ebenfalls positiv auf die Routenwahl aus.

Die Erkenntnisse von Untersuchungen, die auf SP-Experimenten basieren, sind jedoch kritisch zu hinterfragen, da in SP-Experimenten die Proband*innen befragt werden, eine Verifizierung der angegebenen Präferenzen durch die Beobachtung des tatsächlich realisierten Verhaltens (die sog. *Revealed Preference*) jedoch fehlt. Es wird also nicht das Routenwahlverhalten von Radfahrenden beobachtet, sondern die Präferenzen der Radfahrenden, in konstruierten und teils hypothetischen Situationen, abgefragt. Zuteilen entscheiden sich die Befragten dabei anders, als sie es bei einer Entscheidung unter realen Bedingungen tun würden, weil bspw. die konstruierte Situation nicht gut vorstellbar ist (Broach, Dill und Gliebe 2012).

Neuere Studien schließen diese Lücke, indem sie die tatsächlich gewählten Routen von Radfahrenden z.B. mittels GPS-fähigen (Global Positioning System) Geräten erhoben haben und somit über Informationen zur *Revealed Preference* (RP) verfügen. Die im Rahmen der Studien erhobenen GPS-Daten erwiesen sich dabei als zweckmäßig, weil sie detaillierte Informationen zu den zurückgelegten Routen der Radfahrer*innen liefern. Viele

der vorhandenen Studien werteten die erhobenen Daten deskriptiv aus, wodurch kausale Zusammenhänge jedoch in der Regel verborgen blieben. Es existieren darüber hinaus weitere Studien, die auf Grundlage der erhobenen Routendaten multivariate statistische Analysen durchführten. Diese Arbeiten geben einen detaillierten Einblick in die Routenwahl von Radfahrenden und ihre kausalen Wirkungszusammenhänge (siehe Kapitel 3).

Die Ergebnisse dieser Studien lassen sich jedoch nur bedingt auf den deutschen Raum und das Routenwahlverhalten deutscher Radfahrender übertragen. Dies liegt vor allem darin begründet, dass sich Unterschiede durch den Kontext der Erhebungen ergeben. Bei den erhobenen Daten handelt es sich meist um räumlich vereinzelte Datensätze, die auf nichtdeutsche Städte beschränkt sind. Da die Routendaten in unterschiedlichen Städten mit unterschiedlichen geographischen Gegebenheiten und infrastruktureller Ausstattung durchgeführt wurden, ist ein direkter Transfer der Studienergebnisse und der resultierenden Modelle oftmals fraglich. Darüber hinaus sind die Stichprobengrößen der Daten häufig klein (z.B. zu wenige Probanden oder Fahrten) oder die Zusammensetzung der Probandengruppen ist teils zu homogen (z.B. kein ausgeglichenes Geschlechterverhältnis; nur eine bestimmte Gruppe von Radfahrer*innen). Diese Tatsachen können zu einer Verzerrung der Studienergebnisse führen und erschweren die Übertragbarkeit der Ergebnisse (siehe Kapitel 3).

Die Problemstellung lässt sich daher wie folgt zusammenfassen: Die Analyse der Routenwahl ist zur Förderung und Planung des Radverkehrs essentiell. Für den deutschen Raum liegen jedoch keine übertragbaren Studien und Analysemodelle zur Routenwahl im Radverkehr vor, die auf real beobachtetem Verhalten basieren. Die derzeit vorliegenden Ergebnisse existierender, vor allem internationaler, Studien lassen sich wiederum nicht auf den deutschen Raum übertragen.

## 1.3 Fragestellung

Aus den geschilderten Zusammenhängen ergeben sich unterschiedliche Forschungsfragen für die Dissertation. Die zentralen Fragen, die in der vorliegenden Arbeit beantwortet werden sollen, lauten wie folgt:

1. Welche Faktoren üben einen signifikanten Einfluss auf die Routenwahl von Radfahrenden in deutschen Städten (Untersuchungsraum: Dresden) aus?
2. Inwiefern beeinflussen diese Faktoren die Routenwahl positiv oder negativ?
3. Wie stark beeinflussen sie die Wahl oder Ablehnung von unterschiedlichen Routenalternativen?

Zielstellung der Arbeit ist dementsprechend, Einflussfaktoren der Routenwahl zu identifizieren, deren Wirkung zu quantifizieren sowie deren Signifikanz zu bestimmen. Datenbasis der Untersuchung ist ein erhobener GPS-Datensatz, der Auskunft über die von Radfahrenden gewählten Routen im Untersuchungsgebiet (Dresden) gibt. Zur Beantwortung der Forschungsfragen wird die Routenwahl von Radfahrer*innen mittels multivariatem statistischen Verfahren analysiert. Die Analyse soll aufzeigen, welche Faktoren die Routenwahl der Radfahrenden maßgeblich beeinflussen.

## 1.4 Aufbau der Arbeit

Die vorliegende Arbeit gliedert sich in sieben Kapitel. In dem folgenden Kapitel werden zunächst die für das Verständnis der Arbeit notwendigen Grundlagen erläutert. Das Kapitel gibt dazu einen Überblick über Eigenschaften und Bedeutung des Radverkehrs sowie über die Radverkehrsförderung und -planung. Darüber hinaus wird ein grundlegendes Verständnis zur Funktionsweise des GPS geschaffen und ein Überblick über die für die Analyse der Routenwahl relevanten Methoden gegeben.

In Kapitel 3 erfolgt eine umfassende Darstellung über den aktuellen Forschungsstand der Thematik. Dazu werden alle Forschungsarbeiten vorgestellt, die die Routenwahl von Radfahrenden auf Basis von real beobachteten Verhaltensdaten untersucht haben. Der Fokus des Kapitels liegt vor allem auf Studien, die GPS-basierte Daten und multivariate statistische Analyseverfahren für die Untersuchung genutzt haben.

Im darauffolgenden Kapitel 4 wird ein Überblick über die Methoden gegeben, die im Rahmen der Arbeit genutzt werden, um die im Kapitel 3 aufgezeigte Forschungslücke zu schließen. Neben der Darstellung des Untersuchungsgebiets wird in diesem Kapitel vor allem auf die Erhebung und Aufbereitung der genutzten Daten eingegangen. Darüber hinaus werden die Methoden zur Analyse der Routenwahl erläutert. Eine abschließende Beschreibung des methodischen Gesamtablaufs gibt einen Überblick über die Prozesskette und soll ein Verständnis für die Verknüpfung der einzelnen Methoden schaffen.

In Kapitel 5 sind die Ergebnisse der Arbeit dargestellt. Diese umfassen zum einen die Ergebnisse der deskriptiven Auswertung. Zum anderen werden die Ergebnisse der multivariaten Analyse vorgestellt.

Im anschließenden Kapitel 6 erfolgt die Diskussion der erarbeiteten Ergebnisse. Dazu erfolgt sowohl eine Diskussion der Einzelergebnisse als auch eine Einordnung der Ergebnisse in den Forschungskontext. Darüber hinaus werden die für die Arbeit verwendeten Methoden sowie die Ergebnisse einer kritischen Reflexion unterzogen, um Stärken und

Schwächen transparent darzustellen. Abbildung 1 stellt das Vorgehen im Rahmen der vorliegenden Arbeit strukturiert dar.

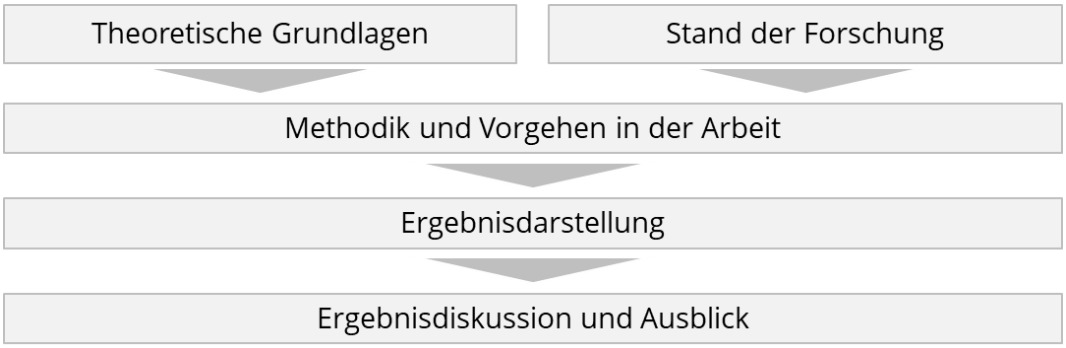


Abbildung 1: Vorgehen im Rahmen der vorliegenden Arbeit

Die Arbeit endet schließlich mit Kapitel 7, in dem ein Fazit gezogen sowie ein Ausblick auf zukünftige Forschungsmöglichkeiten gegeben wird.

# 2. Grundlagen

In diesem Kapitel werden die für das Verständnis der Arbeit notwendigen Grundlagen aufgegriffen. Um den Kontext der vorliegenden Arbeit sowie ihre Ergebnisse besser zu verstehen, wird zunächst ein Überblick über den Radverkehr in Deutschland und seine Eigenschaften gegeben. Darüber hinaus soll ein grundlegendes Verständnis zur Funktionsweise von GPS sowie zu den für die Analyse der Routenwahl relevanten Methoden gegeben werden.

## 2.1 Radverkehr in Deutschland

### 2.1.1 Bedeutung und Eigenschaften

Das Fahrrad wurde in der jüngeren Vergangenheit als praktisches Verkehrsmittel wiederentdeckt (Lohse und Schnabel 2011). Seine Bedeutung, vor allem für die Alltagsmobilität, hat in den letzten 15 Jahren deutschlandweit zugenommen (Nobis 2019). Radfahren liegt im Trend, bietet über kurze und mittlere Distanzen für viele Nutzer*innen eine überzeugende Alternative zum Auto und stellt eine sinnvolle Ergänzung des öffentlichen Verkehrs dar (BMVI 2014).

Dies spiegelt sich auch in Verkehrsstatistiken wieder, in denen sich eine positive Entwicklung der Radverkehrsanteile beobachten lässt. Die Anzahl der Wege, die deutschlandweit mit dem Fahrrad zurückgelegt wurden, ist vom Jahr 2002 bis 2008 um ca. 17 % angestiegen (MiD 2008). Dieser Trend setzte sich in der jüngeren Vergangenheit fort und führte vor allem in Städten zu einem weiteren Anstieg der Fahrradnutzung (Ahrens 2014). Nach MiD 2018 wurden im Jahr 2016/17 ca. 11 % aller Wege mit dem Fahrrad zurückgelegt. Auch dieser Anteil hat in den letzten Jahren eine Steigerung erfahren (siehe Abbildung 2). Eine ähnliche Steigerung konnte in den letzten Jahren bei der Verkehrsleistung, also den zurückgelegten Personenkilometern (Pkm), beobachtet werden (MiD 2018).[1]

[1] Der Anteil an der Verkehrsleistung ist insgesamt jedoch durch die Steigerung der Gesamtverkehrsleistung gleichgeblieben und liegt konstant bei ca. 3 % (Nobis 2019)

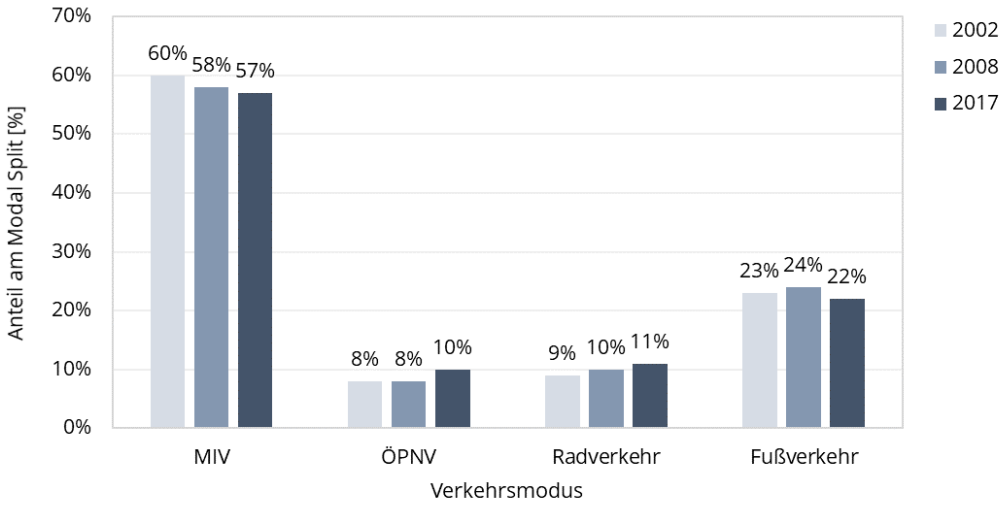


Abbildung 2: Entwicklung des Verkehrsaufkommens in Deutschland (Eigene Darstellung nach Nobis 2019)

In Deutschland existierten im Jahr 2019 insgesamt ca. 75,9 Mio. Fahrräder in privaten Haushalten (ZIV 2020). Bei einer Bevölkerung von rund 83,2 Mio. (DESTATIS 2020) ergibt sich eine sehr hohe Fahrradbesitzquote von ca. 91,2 %. Bei rund 41,5 Mio. privaten Haushalten (DESTATIS 2020) kommen damit im Durchschnitt ca. 183 Fahrräder auf 100 Haushalte. Die entspricht nahezu zwei Fahrrädern pro Haushalt.[2]

Bei einer differenzierten Betrachtung der Fahrradnutzung sind deutliche Unterschiede festzustellen. Eine Unterscheidung nach Lebensphasen zeigt beispielsweise auf, dass das Fahrrad am häufigsten von Schüler*innen und Student*innen genutzt wird (17 % bzw. 12 % im Modal Split). Es zeigt sich darüber hinaus, dass Menschen mit flexibler Zeiteinteilung (bspw. Teilzeitbeschäftigte, Hausfrauen oder Rentner*innen) das Fahrrad stark nutzten (ca. 10 % am Modal Split). Kinder und Vollzeitberufstätige weisen hingegen eher geringe Nutzungsraten auf (je 8 % im Modal Split). Zudem ist insgesamt eine häufigere Nutzung durch männliche Radfahrende zu beobachten (BMVI 2014). Neben Lebensphasen und Geschlecht spielen auch Milieus eine wichtige Rolle. Befragungen des SINUS-Instituts zur Folge nutzen besonders sog. „Expeditive“ und „Performer“ aus der Mittel- und Oberschicht das Fahrrad, weil sie sich z.B. an bestimmten Life Styles orientieren (SINUS 2019). Bei „traditionell eingestellten“ Menschen der unteren Schichten ist hingegen eine geringere Nutzung zu beobachten (ebd.).

Die Nutzung des Fahrrads unterscheidet sich außerdem im Hinblick auf die Wegezwecke. Am häufigsten wird das Rad für Wege genutzt, die im Rahmen von Freizeitaktivitäten

[2] Es ist jedoch zu beachten, dass nicht jeder Bundesbürger*innen ein Fahrrad besitzt, denn die Fahrräder sind ungleich über die Haushalte verteilt (BMVI 2014)

zurückgelegt werden (31 %). Es folgen Wege zur bzw. von der Arbeit (19 %), Versorgungswege (16 %) und andere private Erledigungen (13 %). Dienstliche Wege werden nur selten mit dem Rad zurückgelegt (Nobis 2019).

Der Grund für die unterschiedlich ausgeprägte Nutzung des Fahrrads besteht vor allem in den Eigenschaften des „Systems“ Fahrrad bzw. den „systeminhärenten“ Beschränkungen des Radverkehrs. Dazu gehört bspw. die im Vergleich zum MIV oder ÖV geringeren realisierbaren Maximalgeschwindigkeiten, die von der Physis der Radfahrenden sowie den infrastrukturellen und betrieblichen Eigenschaften des Radverkehrsangebots (z.B. Oberflächenqualität oder Vorfahrtsregelung an Knotenpunkten) abhängen. Dadurch ergeben sich bei einem begrenzten Mobilitätszeitbudget begrenzte Bewegungsradien. Aus diesem Grund wird das Fahrrad meist auf kurzen Wegen (bis 5 km) genutzt. Etwa 90 % aller Wege mit dem Rad sind kürzer als 5 km (MiD 2008) und die durchschnittliche Wegelänge beträgt nur etwa 3,4 km (Nobis 2019). Dementsprechend wird das Fahrrad v.a. für kürzere Wege genutzt. Dies ist in der Regel in urbanen Gebieten und Städten der Fall. Da Wege auf dem Land deutlich länger sind, wird das Fahrrad dort vergleichsweise seltener genutzt. Diese Stadt-Land-Unterschiede lassen sich bei der Fahrradnutzung in vielen Bundesländern feststellen. Der Anteil des Fahrrads am Modal Split liegt bspw. in Sachsen bei ca. 8 %, während er in den Städten des Bundeslands meist deutlich höher ist (z.B. 16 % in Dresden). Die häufigste Nutzung findet jedoch nicht in Großstädten statt, sondern in Städten mit 50.000-100.000 Einwohnern. Dies ist vermutlich darauf zurückzuführen, dass in diesen Städten die Wege weniger lang sind als in Großstädten oder auf dem Land (BMVI 2014).

Es können jedoch auch deutliche Unterschiede zwischen Städten gleicher Größe existieren, da nicht nur die Größe einer Stadt bzw. die damit verbundenen Wegelängen einen Einfluss auf die Fahrradnutzung haben. Andere Treiber oder Barrieren der Fahrradnutzung, wie bspw. die infrastrukturelle Ausstattung mit Radwegen oder Möglichkeiten zur Verknüpfung von Radfahrten mit dem Öffentlichen Personenverkehr (ÖPV), üben ebenfalls einen Einfluss auf die Fahrradnutzung aus. Zwar ist die Mehrzahl der Radfahrer*innen monomodal unterwegs, es kombinieren jedoch rund ein Drittel der Radfahrenden das Fahrrad mit dem ÖPV (SINUS 2019). Darüber hinaus beurteilen mehr als drei Viertel der Radfahrenden (77 %) die Kombination von Fahrrad und ÖPV als wichtig oder sehr wichtig (BMVI 2014).

Ein weiterer wichtiger Aspekt der Fahrradnutzung ist die Sicherheit. Die meisten Unfälle mit Personenschaden finden im Radverkehr innerorts statt, wobei die Mehrzahl Unfälle mit Pkw-Beteiligung oder Alleinunfälle sind (DESTATIS 2019). Die Anzahl verletzter

Radfahrer*innen hat im Vergleich zu den insgesamt Verletzten im Verkehr seit dem Jahr 2010 überproportional zugenommen. Im Radverkehr wurden nicht die gleichen Erfolge bzgl. der Verkehrssicherheit erzielt, wie in anderen Bereichen des Verkehrs (DESTATIS 2020). Für die Bereitschaft der Fahrradnutzung spielt neben der objektiven Sicherheit die subjektive Sicherheit eine wichtige Rolle. Nahezu die Hälfte der deutschen Radfahrenden (ca. 47 %) fühlen sich (eher) unsicher beim Radfahren (SINUS 2019). Diese Unsicherheit hat mehrere Ursachen. Sie wird vor allem durch ein hohes Verkehrsaufkommen des fließenden motorisierten Verkehrs (MV) und seine hohen Geschwindigkeiten negativ beeinflusst. Ungeeignete Führungsformen und fehlende Rücksicht anderer Verkehrsteilnehmer*innen sind weitere Einflussfaktoren, die sich negativ auf das Sicherheitsempfinden auswirken (SINUS 2019).

Die Beliebtheit des Fahrrads ist in den vergangenen Jahren weiter gestiegen. Im Jahr 2017 gaben bspw. im Rahmen der Erhebung zum Fahrradmonitor rund 63 % der Befragten an, das Fahrrad gern oder sehr gern zu nutzen. Im Jahr 2015 waren es noch neun Prozentpunkte weniger. Die Nutzung des Fahrrads könnte auch perspektivisch weiter ansteigen: ca. 34 % der Befragten wollen das Fahrrad zukünftig häufiger nutzen (SINUS 2019). Eine zunehmende Anzahl attraktiver Angebote (z.B. Radwege, Abstellmöglichkeiten) sowie Weiterentwicklungen des Fahrrads an sich (z.B. elektrisch unterstütztes Fahren mittels Pedelec) können einen wichtigen Beitrag leisten, um die Nutzung des Fahrrads weiter zu steigern.

### 2.1.2 Vorteile und Potentiale des Radverkehrs

Das Fahrrad ist ein kostensparendes, raumeffizientes und umweltfreundliches Verkehrsmittel (UBA 2019). Es bietet gegenüber anderen Verkehrsmitteln zahlreiche Vorteile, die vor allem auf der individuellen Ebene (der Nutzer*innen) bestehen. Es existieren jedoch auch gesamtgesellschaftliche Vorteile.

Auf der Seite der Nutzer*innen bestehen vor allem in praktischer, gesundheitlicher sowie kostenbezogener Hinsicht Vorteile der Fahrradnutzung. Praktische Vorteile beziehen sich vor allem auf die Reisezeit. So ist das Fahrrad im städtischen Verkehr, vor allem auf kurzen Distanzen (≤ 5 km), häufig ein sehr schnelles Verkehrsmittel (siehe Abbildung *3*).

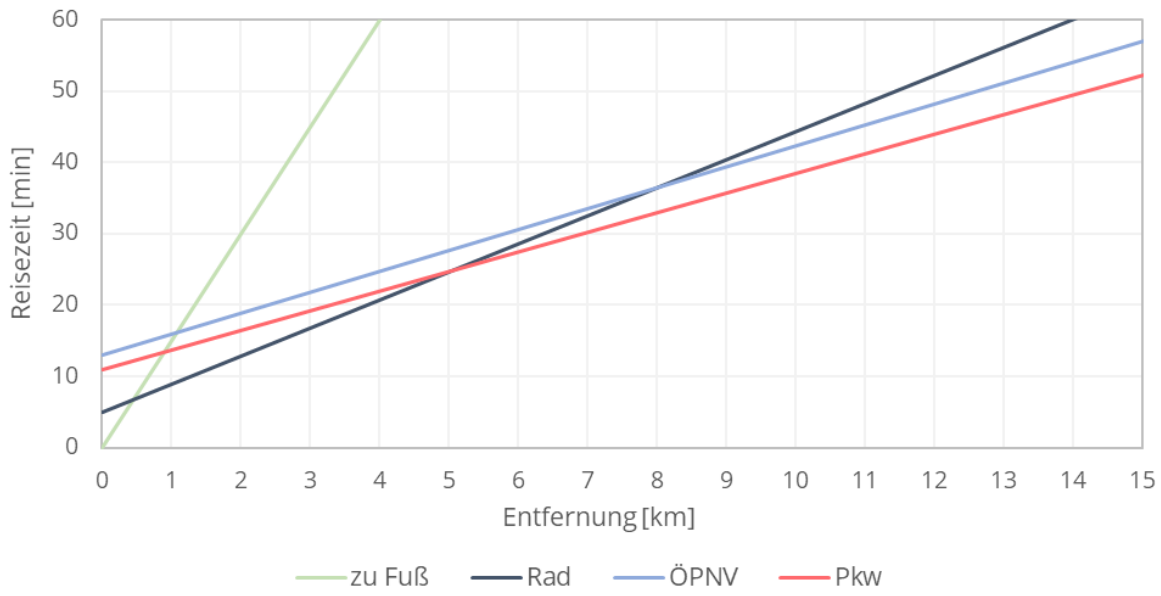


Abbildung 3: Vergleich der Reisezeiten unterschiedlicher Verkehrsmittel im Stadtverkehr von „Tür-zu-Tür“ (Eigene Darstellung nach UBA 2019)

Über diese Vorteile hinaus birgt die Verwendung des Fahrrads zudem einen großen gesundheitlichen Nutzen für die Radfahrenden selbst. Tägliches Radfahren steigert die motorischen Fähigkeiten, führt zu einem Zugewinn an Fitness und Wohlbefinden sowie zu einer erheblichen Reduktion des Risikos an Zivilisationskrankheiten (z.B. Übergewicht oder Kreislauferkrankungen) zu leiden. Vermeintliche Nachteile des Radfahrens, wie bspw. ein höheres Unfallrisiko oder starke Exposition gegenüber Luftschadstoffen werden von den gesundheitlichen Vorteilen, die durch die zusätzliche Bewegung entstehen, kompensiert (UBA 2019).

Neben den praktischen und gesundheitlichen Vorteilen entsteht zudem ein großer ökonomischer Nutzen durch die Verwendung des Fahrrads als alltägliches Verkehrsmittel. Anschaffung und Unterhalt eines Fahrrads sind deutlich günstiger als bei einem Pkw. Die durchschnittlichen Nutzungskosten eines Fahrrads liegen bei ca. 0,10 €/km. Bei einem durchschnittlichen Pkw ergeben sich dagegen durchschnittliche Nutzungskosten zwischen 0,30 €/km und 0,60 €/km (UBA 2019). Bei innerstädtischen Wegen können sich die Kosten teilweise noch deutlicher Unterscheiden (VCD 2020).

Die Verwendung des Fahrrads ist nicht nur individuell, sondern auch volkswirtschaftlich sinnvoll. Zwar lässt sich der volkswirtschaftliche Gewinn, der sich aus der gesundheitsfördernden Wirkung des Radfahrens ergibt, nur schwer quantifizieren. Studien zeigen jedoch bspw. auf, dass Radfahrer*innen weniger häufig krankheitsbedingt fehlen als Arbeitnehmer*innen, die kein bzw. kaum Rad fahren. Ökonomische Vorteile der geringeren Anzahl an krankheitsbedingten Ausfällen sind offensichtlich. Darüber hinaus verursacht

der Radverkehr im Vergleich zum MIV nur sehr geringe externe Kosten, die hauptsächlich aus Luftverschmutzung, Lärm, Treibhausgasemissionen oder Eingriffen in Natur und Landschaft resultieren und die von der Allgemeinheit getragen werden müssen (Brenck, Mituschi und Winter 2007). Zudem sind Bau und Unterhalt von Radverkehrsinfrastruktur deutlich günstiger als Infrastruktur für den MIV (UBA 2019).

Darüber hinaus besteht ein Nutzen des Radverkehrs vor allem darin, dass Radfahren eine umweltfreundliche und klimaschonende Art der Fortbewegung ist. Die Vorteile lassen sich unter den Stichworten „emissionsarm", „flächensparsam" und „geräuscharm" subsummieren. Beim Radfahren werden keine klima- oder gesundheitsschädlichen Luftschadstoffe emittiert (z.B. $NO_x$, $PM_{10}$ oder $CO_2$). Zudem beansprucht der Radverkehr insgesamt weniger Verkehrsfläche als der motorisierte Straßenverkehr (nur ca. 10 %). Diese „Flächensparsamkeit" betrifft ebenso den ruhenden Verkehr: Auf dem Stellplatz eines Pkw können etwa acht bis zehn Fahrradstellplätze eingerichtet werden (UBA 2019). Überdies ist Radverkehr geräuscharmer Verkehr. Die derzeit hohe Lärmbelastung durch den MIV hat starke negative Auswirkungen auf die Bevölkerung (z.B. steigendes Herzinfarktrisiko oder Schlafstörungen). Der Radverkehr leistet daher einen bedeutenden Beitrag zur Verringerung von Verkehrslärm und hilft damit, die in den Städten lebenden Menschen sowie die Umwelt zu entlasten (UBA 2019).

Das Potential zur Verlagerung von Fahrten auf den Radverkehr wird insgesamt als relativ hoch eingeschätzt. Von den rund 256 Mio. Wegen, die in Deutschland täglich zurückgelegt werden, entfallen nur ca. 11 % auf den Radverkehr. Rund 3 % der Verkehrsleistung werden im Personenverkehr mit dem Rad erbracht (MiD 2018). Die Beschreibung der Eigenschaften des Fahrrads und der statistischen Kennziffern hat bereits aufgezeigt, dass das Fahrrad bei mittleren und großen Entfernungen für den Großteil der Verkehrsteilnehmer*innen keine Alternative zu anderen Verkehrsmitteln darstellt. Auf kurzen Strecken (≤ 5 km) kann es jedoch eine relevante Alternative zu anderen Verkehrsmitteln sein (UBA 2013). Rund 40 % bis 50 % aller Autofahrten in Deutschland werden auf Strecken durchgeführt, die kürzer als 5 km sind. Rund ein Viertel der Strecken sind sogar kürzer als 2 km. Es sind diese kurzen Wege, die sich potentiell sehr gut mit dem Fahrrad zurücklegen lassen und für die sich ein entsprechend hohes Substitutionspotential ergibt (UBA 2019).

Dass ein hoher Anteil des Fahrrads im Modal Split von 30 % und mehr erreichbar und realistisch ist, lässt sich in vielen anderen europäischen Ländern beobachten. Städte wie Amsterdam, Kopenhagen oder auch Münster in Deutschland weisen hohe Anteile des Fahrrads am Modal Split aus (45 %, 35 % bzw. 38 %). Ließe sich der Radverkehrsanteil in Deutschland auf ein ähnlich hohes Niveau wie bspw. in den Niederlanden bringen, so

könnte der Radverkehr einen signifikanten Teil zu dem von der Bundesregierung ausgeschriebenem Ziel der $CO_2$-Reduktion im Verkehrsbereich beitragen (UBA 2019).

Das Potential des Radverkehrs kann jedoch nicht überall in gleichem Maße gehoben werden, da zentrale Faktoren existieren, die das Radverkehrsaufkommen in Städten beeinflussen. Topographie, Klima, Siedlungsstruktur, das Angebot im Öffentlichen Personennahverkehr (ÖPNV) und Fahrzeugverfügbarkeit, Bevölkerungsstruktur und Radverkehrsinfrastruktur machen eine angepasste Förderung des Radverkehrs notwendig (Bohrmann und Thiemann-Linden 2012).

### 2.1.3 Radverkehrsförderung und -planung

Um einerseits auf die aktuellen Entwicklungen der steigenden Radverkehrsnachfrage zu reagieren und andererseits zusätzliche Angebote zu schaffen, ist eine zielgerichtete Radverkehrsplanung und -förderung notwendig. Für eine weitere Steigerung der Radverkehrsanteile fördern Bund, Länder und Kommunen im Rahmen der föderalen Aufgabenteilung gemeinsam den Radverkehr. Während der Bund vor allem als Gesetzgeber die notwendigen Rahmenbedingungen für den Radverkehr schafft und mit dem Nationalen Radverkehrsplan auf Bundesebene Impulse für die Radverkehrsförderung setzt (siehe NRVP 2020), sind die Länder und Kommunen hauptsächlich für die Umsetzung konkreter Maßnahmen vor Ort zuständig (NRVP 2020).

Das obergeordnete Ziel aller Maßnahmen der Radverkehrsförderung besteht ganz allgemein in der Verbesserung bzw. Optimierung der Rahmenbedingungen für die Fahrradnutzung. Für die Erreichung dieses Ziels können unterschiedliche Maßnahmen ergriffen werden. Diese reichen von der Umsetzung von Einzelmaßnahmen (z.B. Neu- oder Ausbau von Radwegen), über die Schaffung eines flächendeckenden Radverkehrsnetzes (z.B. Erhöhung der Netzdichte) bis hin zum Aufbau eines mit dem ÖPNV verknüpften Radverkehrssystems (z.B. Integration von Bike-Sharing in den Verkehrsverbund) (Krause und Hildebrandt 2006). Die Förderung des Radverkehrs endet jedoch prinzipiell nicht bei „harten Maßnahmen“ wie bspw. der Umgestaltung von Infrastruktur, sondern umfasst ebenso „weiche Maßnahmen“ wie z.B. die Förderung eines positiven Images des Radverkehrs oder Mobilitätserziehung (UBA 2019).

Der Aufbau einer adäquaten, also an die Bedürfnisse der Radfahrenden angepassten, Infrastruktur ist jedoch eine elementare Aufgabe der Radverkehrsförderung/-planung. Eine den Radverkehr fördernde Infrastruktur sollte derart ausgestaltet sein, dass Radfahrende möglichst direkt, schnell, sicher und komfortabel unterwegs sind (UBA 2019). Es

existiert ein breites Spektrum an Maßnahmen, die die Bedingungen für Radfahrende insgesamt verbessern und das Radfahren attraktiver gestalten können. Zahlreiche Empfehlungen und Beispiele aus der Planungspraxis können bspw. in BMVIT 2013 oder VCD 2016 gefunden werden. Klassische Maßnahmen sind z.B. Neu-, Um- oder Ausbau von Radwegen, die Entflechtung gemeinsam geführter Geh- und Radwege, die Öffnung von Einbahnstraßen und Fußgängerzonen für den Radverkehr oder die Ausweitung von Geschwindigkeitsbegrenzungen (Tempo 30) für den MIV. Für die konkrete Umsetzung existieren Regelwerke wie bspw. die „Empfehlungen für Radverkehrsanlagen (ERA)“ (FGSV 2010) oder die „Richtlinien für die Anlage von Stadtstraßen (RASt)“ (FGSV 2006).

Damit entsprechende Maßnahmen möglichst effektiv wirken, bedarf es einer zielgerichteten Planung. Das Gesamtziel der Radverkehrsplanung ist es, sicherzustellen, dass Radverkehr auf eine sichere und effiziente Art und Weise und möglichst mit der gewünschten Qualität stattfinden kann. Zur Gewährleistung der Zielerreichung sind innerhalb der (Rad-)Verkehrsplanung grundsätzlich die in Abbildung *4* dargestellten Schritte notwendig (FGSV 2018).

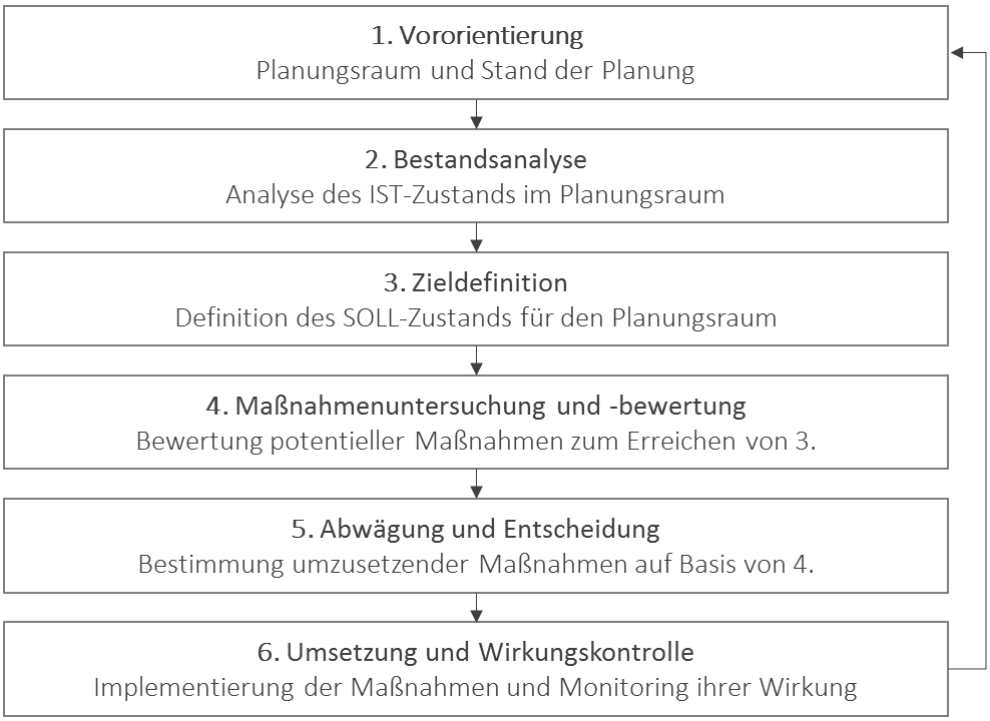


Abbildung 4: Ablauf der zielorientierten Verkehrsplanung (Eigene Darstellung nach FGSV 2018)

Im Rahmen einer zielorientierten Planung müssen zunächst Problem- und Bestandsanalysen (Analyse des Ist-Zustands) durchgeführt und Ziele definiert werden (Vorgabe des Soll-Zustands). Anschließend können potentielle Maßnahmen untersucht und im Hinblick auf ihre Wirkung bewertet werden (FGSV 2018).

Die Entscheidung für oder gegen die Umsetzung einer Maßnahme basiert im Wesentlichen auf der Wirkung jeder einzelnen Maßnahme sowie deren Bewertung (siehe Punkt 4 in Abbildung *4*). Eine wichtige Entscheidungsgröße ist dabei die potentielle Nutzung eines zu schaffenden Verkehrsangebots (z.B. einer Radverkehrsanalage) durch die Radfahrenden. Um die potentielle Nutzung zu quantifizieren und faktenbasiert Entscheidungen treffen zu können, werden unterschiedliche Methoden angewendet.

Eine Möglichkeit besteht bspw. in der Durchführung von Befragungen zum Verhalten und zu Präferenzen der Radfahrenden (FGSV 2012). Diese Umfragen können helfen, das Verkehrsverhalten zu verstehen und darüber hinaus Informationen zum Verkehrsverhalten in hypothetischen Situationen zu erheben. Befragungen können somit helfen, eine potentielle Maßnahme zu bewerten und so zwischen unterschiedlichen Maßnahmen zu priorisieren. Ein Nachteil solcher Befragungen ist jedoch, dass lediglich die geäußerte Präferenz und nicht das beobachtete Verhalten für die Entscheidung zur Umsetzung einer Maßnahme vorliegt und das reale Verhalten nicht zwangsläufig mit der geäußerten Präferenz übereinstimmen muss (Schneider, et al. 2011).

Eine weitere Möglichkeit zur Wirkungsabschätzung potentieller Maßnahmen ist es, das realisierte Verhalten von Radfahrenden (z.B. die Routenwahl) zu beobachten und statistisch auszuwerten. Die Analyseergebnisse können anschließend a) Aufschluss über die Präferenzen der Radfahrenden geben und b) für Prognosen und Wirkungsabschätzungen in Verkehrsmodellen eingesetzt werden. Verkehrsmodelle sind in der Lage vorhandene Zustände in einem Verkehrsnetz zu rekonstruieren und die Wirkungen geplanter verkehrlicher Maßnahmen (z.B. Änderung der Radverkehrsführung) auf die Verkehrsnachfrage (z.B. Routenwahl der Radfahrenden) abzubilden. Die Ergebnisse können schließlich als Grundlage genutzt werden, um bspw. zu entscheiden, wo Radwege neu gebaut oder Radverkehrsführungsformen umgestaltet werden sollten (Zimmermann, Mai und Frejinger 2017).

Dazu sind jedoch Analysen und Modelle notwendig, die einen Einblick in das Radverkehrsverhalten geben und eine realistische Abbildung der Routenwahl zulassen. An dieser Stelle setzte die vorliegende Arbeit an.

## 2.2 Analyse und Modellierung von Entscheidungen

Damit Routenwahlentscheidungen analysiert und in Verkehrsnachfragemodellen abgebildet werden können, müssen sie quantifiziert werden. Die Quantifizierung erfolgt mit

Hilfe von Entscheidungsmodellen. Mit ihnen wird versucht vorhandene Zustände in einem (Verkehrs-)System zu analysieren und zu rekonstruieren. Sind aufgrund der Analyse bspw. die entscheidenden Einflussfaktoren der Routenwahl bekannt, so hilft dies einerseits menschliche Entscheidungen zu verstehen. Andererseits können die resultierenden Modelle genutzt werden, um zukünftige Entscheidungen realistisch abzubilden und damit im Rahmen der Verkehrsplanung die Wirkungen potentieller Maßnahmen abzuschätzen (siehe Kapitel 2.1.3). Für die Analyse und Abbildung von Entscheidungen bedarf es spezieller Daten und Methoden, deren grundlegende Erläuterung Gegenstand dieses Kapitels sein soll.

### 2.2.1 Diskrete Wahltheorie

Viele Sachverhalte des Verkehrsverhaltens, wie auch die Routenwahl, basieren auf diskreten Entscheidungen. Diskret bedeutet, dass die Entscheidung von Verkehrsteilnehmer*innen nur eine ganz bestimmte Ausprägung annehmen kann. Die Wahl einer Route ist eine solche diskrete Entscheidung, bei der die Ausprägung der abhängigen Variable (Wahl einer Route) nicht stetig, sondern kategorial (ja oder nein) ist.

Die diskrete Wahltheorie wurde in den 1970er und 1980er Jahren insbesondere durch McFadden 1976, Ben-Akiva und Lerman 1985 und andere entwickelt. Sie trieben vor allem die Entwicklung des heute sehr gebräuchlichen Logit-Modells voran. Die Entwicklung liegt darin begründet, dass die Einflüsse auf diskrete Variablen nicht mit dem Verfahren der klassischen linearen Regressionsanalyse untersucht werden können (siehe Kapitel 2.2.2).

Entscheidungen werden durch bestimmte Einflussfaktoren, sog. exogene Variablen, beeinflusst. Im Verkehrsbereich ist die Reisezeit ein klassisches Beispiel für solche Einflussfaktoren (z.B. in der Modus- oder Routenwahl). Die Werte exogener Variablen (z.B. Reisezeit) können jeweils für die unterschiedlichen Alternativen, zwischen denen Entscheider*innen auswählen, berechnet werden. Sie sind ein wichtiger Input für die Analyse der Wahlentscheidung. Gemäß dem klassischen wirtschaftstheoretischen Modell der Nutzenmaximierung wird in der diskreten Wahltheorie davon ausgegangen, dass von Entscheider*innen die Alternative mit dem für sie maximalen Nutzen gewählt wird (Pollert, Kirchner und Polzin 2016). Allerdings setzt diese Annahme voraus, dass diese über die vollständige Information verfügen – ihnen also sämtliche Alternativen mit all ihren Eigenschaften bekannt sind (Prinzip des *Homo Oeconomicus*).

Diese Konsistenz ist in der Realität jedoch nicht oder nur äußerst selten gegeben, weshalb in der diskreten Wahltheorie zwei unterschiedliche Nutzen-Komponenten eingeführt wurden. Eine Komponente beschreibt den beobachtbaren Nutzen, der sich durch

Beobachtungen oder Berechnungen quantifizieren lässt. Sie wird deterministische Nutzenkomponente genannt. Daneben existiert ein sog. Zufallsnutzen, der den zufälligen bzw. nicht beobachtbaren Nutzen darstellt (Schnabel und Lohse 2011). Der Zufallsnutzen (auch Zufallsterm genannt) stellt eigentlich nichts anderes dar, als das Eingeständnis vom Unwissen der Beobachtenden (Treiber 2018). Zusammen mit der deterministischen Nutzenkomponente ergibt sich damit der Gesamtnutzen

$$U_{ik} = V_{ik} + \varepsilon_{ik} \tag{1}$$

mit $U_{ik}$ als Gesamtnutzen, $V_{ik}$ als deterministischen Nutzen sowie $\varepsilon_{ik}$ als Zufallsnutzen einer Person *i* und Alternative *k*. Der deterministische Nutzen kann mittels Analysen aus den Beobachtungen abgeleitet und statistisch geschätzt werden. Dazu werden die quantifizierbaren Eigenschaften in Form von Aufwänden (z.B. Reisezeiten oder Kosten einer Alternative) in die deterministische Nutzenkomponente integriert (Schnabel und Lohse 2011). Es ergibt sich damit der erweiterte deterministische Nutzen $V_{ik}$ nach

$$V_{ik} = \beta_0 + \beta_{1ik} * X_{1ik} + \beta_{2ik} * X_{2ik} + \ldots + \beta_{nik} * X_{nik} \tag{2}$$

mit $X_{ik}$ als Aufwand einer quantifizierbaren Eigenschaft *n* (z.B. Reisezeiten oder Kosten einer Alternative) für Person *i* und Alternative *k*. Darüber hinaus werden die alternativenspezifische Konstante $\beta_0$ (sie beschreibt die globale Präferenz einer Alternative) und die aufwandsspezifischen Koeffizienten $\beta_{nik}$ eingeführt, die den Einfluss des Aufwands $X_{ik}$ auf den deterministischen Nutzen-Term beschreiben. Sie stellen im Wesentlichen Gewichtungsparameter dar, welche die subjektive Erhöhung/Verringerung des Nutzens einer Alternative *k* für eine Person *i* beschreiben. Es ergibt sich daraus der Gesamtnutzen

$$U_{ik} = \beta_{0ik} + \beta_{1ik} * X_{1ik} + \beta_{2ik} * X_{2ik} + \ldots + \beta_{nik} * X_{nik} + \varepsilon_{ik} \tag{3}$$

Über die Zufallskomponente (nicht beobachtbarer Nutzen) und deren Verteilung müssen Annahmen getroffen werden. Sie sind Grundlage für die Auswahl eines geeigneten Entscheidungsmodells.

### 2.2.2 Multiple logistische Regressionsanalyse

Diskrete Entscheidungen können aufgrund ihrer Eigenschaften (kategoriale Ausprägung) nicht mit der klassischen linearen Regressionsanalyse untersucht werden, weil Funktionen linearer Regressionsmodelle stetige Werte ausgeben und keine obere und untere Grenze aufweisen (siehe Abbildung *5*). Bei der diskreten Wahl geht es meist um zwei

alternative Zustände: eine Alternative wird gewählt oder nicht. Aufgrund der Dichotomie der abhängigen Variable „Wahl“ müssen zur Analyse und Abbildung diskreter Entscheidungen Verfahren bzw. Modelle der diskreten Wahltheorie genutzt werden (Backhaus, et al. 2016). Sie werden „mikroskopisch” formuliert. Das bedeutet, dass grundsätzlich Einzelentscheidungen individueller Personen betrachtet werden (Treiber 2018).

Die logistische Regressionsanalyse ist ein derartiges Verfahren bzw. Modell, das für die Analyse diskreter Entscheidungen genutzt werden kann. Sie ist ein strukturprüfendes Verfahren, mit dem der Einfluss von unabhängigen Variablen *X* auf die abhängige Variable *Y* analysiert wird. Im Gegensatz zur linearen Regressionsanalyse besteht jedoch die Besonderheit, dass *Y* kategorial ausgeprägt ist. Die Ausprägung ($a = 1, \ldots, A$) von *Y* repräsentiert die möglichen Alternativen. Existieren zwei Alternativen ($A = 2$) ist *Y* eine dichotome bzw. binäre Variable. In diesem Fall spricht man von binärer logistischer Regression. Existieren mehrere unterschiedliche unabhängige Variablen, die die Ausprägung der abhängigen Variablen beeinflussen, so handelt es sich um eine multiple logistische Regression (ebd.).

Im binären Fall sind die Alternativen meist mit 0 und 1 indiziert. *Y* wird in dem Fall auch als „0,1-Variable“ bezeichnet. Für die Wahrscheinlichkeiten gilt dann:

$$P\ (Y = 0) = 1 - P\ (Y = 1) \tag{4}$$

Die Wahrscheinlichkeit $P\ (Y = 1)$ für den Eintritt des Ereignis 1 (z.B. Wahl einer Route) ist dabei eine Funktion der gegebenen unabhängigen Variablen $x_1, \ldots, x_n$, die die Ausprägung der abhängigen Variablen beeinflussen. Für die Analyse werden alle unabhängigen Variablen miteinander kombiniert, sodass sich die folgende Linearkombination ergibt:

$$z(x) = \beta_0 + \beta_1 x_1 + \ \ldots + \beta_n x_n \tag{5}$$

$Z(x)$ wird in der Modelltheorie auch als deterministische oder systematische Komponente des Modells bezeichnet (siehe Kapitel 2.2.1). Sie ist abhängig von den Ausprägungen der unabhängigen Variablen $x_n$ und ihren jeweiligen Regressionskoeffizienten $\beta_n$. Bis zu diesem Punkt ist das Modell identisch mit dem linearen Regressionsmodell. Für das logistische Regressionsmodell wird jedoch die logistische Funktion

$$p = \frac{e^z}{1 + e^z} = \frac{1}{1 + e^{-z}} \tag{6}$$

genutzt (mit *p* als Eintrittswahrscheinlichkeit eines Ereignisses und der Eulerschen Zahl *e = 2,71828*). *Z* stellt den sog. Logit dar. Dabei handelt es sich um ein lineares Regressionsmodell der unabhängigen Variablen. Im Gegensatz zur linearen Funktion besitzt sie einen s-förmigen Verlauf. Sie kann als Verteilungsfunktion interpretiert werden (also als eine kumulative Wahrscheinlichkeitsverteilung) und kommt der Normalverteilung sehr nahe. Die logistische Funktion verläuft asymptotisch gegen die Werte 0 und 1 und kann zur Transformation reell-wertiger Variablen in Wahrscheinlichkeiten genutzt werden. Damit lassen reelle Zahlen des Wertebereichs [-∞, +∞] in den Wertebereich [0, 1] überführen (ebd.). Abbildung *5* verdeutlicht den Sachverhalt beispielhaft für den binären Fall.

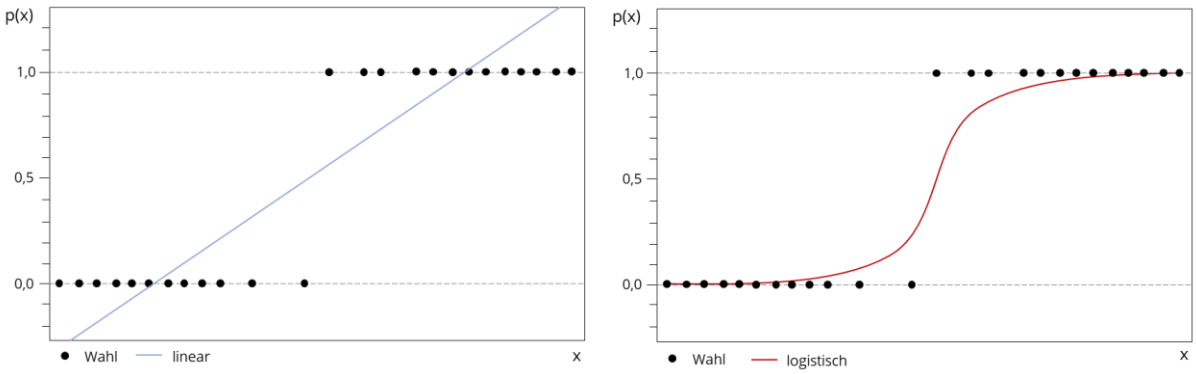


Abbildung 5: Lineare und logistische Funktion (Eigene Darstellung nach Backhaus, et al. 2016)

Wird die systematische Komponente mit der logistischen Funktion transformiert, so ergibt sich die logistische Regressionsfunktion:

$$p(x) = \frac{1}{1 + e^{-z(x)}} \tag{7}$$

In dem Fall bildet *z(x)* den Prädiktor für die Wahrscheinlichkeit *p(x)*. Wird nun die systematische Komponente, die die unabhängigen Variablen beinhaltet, in die Regressionsfunktion integriert, dann ergibt sich aus (7) und (5):

$$p(x) = \frac{1}{1 + e^{-\beta_0 + \beta_1 x_1 + \ldots + \beta_n x_n}} \tag{8}$$

Im multinomialen Fall, wenn also mehr als zwei Alternativen zur Wahl stehen, erweitert sich (8) zu (9). In diesem Fall ergibt sich die Wahlwahrscheinlichkeit aus dem Quotienten des exponierten Nutzens einer Alternative und der Summe der exponierten Nutzen aller Alternativen.

$$p(x) = \frac{e^{-\beta_0+\beta_1 x_1+ \dots +\beta_n x_n}}{\sum e^{-\beta_0+\beta_1 x_1+ \dots +\beta_n x_n}} \tag{9}$$

Die logistische Regressionsfunktion bildet mit ihrem Verlauf gegen die binären Werte (y = 0 oder y = 1) die Wahrscheinlichkeit für y = 1 ab. Es werden also, anders als bei der linearen Regression, nicht konkrete Werte vorhergesagt. Die logistische Funktion gibt die Eintrittswahrscheinlichkeit, dass y den Wert 1 annimmt, an. Ein Wert nahe 1 zeigt an, dass ein Eintreten von y = 1 (z.B. Wahl einer Route) sehr wahrscheinlich ist, während ein Wert nahe 0 anzeigt, dass ein Eintreten dieses Ereignisses eher unwahrscheinlich ist (Schwarz 2018).

Die sog. Logit-Modelle sind die mit Abstand am häufigsten genutzten Modelle, wenn es um die Analyse und Modellierung von diskreten Entscheidungen geht. Vor allem das Binomiale Logit (BNL) sowie das Multinomiale Logit (MNL) sind beliebte und häufig verwendete Modelle. Sie werden vor allem aufgrund ihrer einfachen Handhabung in einer Vielzahl von Forschungsdisziplinen, in denen diskrete Wahlentscheidungen untersucht werden, angewendet (Wolf und Best 2010).

Es sei der Vollständigkeit halber darauf hingewiesen, dass viele unterschiedliche Modelle für die Abbildung von diskreten Entscheidungen existieren und genutzt werden können. Bi- und Multinomiale Probit-Modelle, sog. GEV-Modelle (Generalized Extreme Value), Nested Logit, Paired Combinaional Logit oder Generalized Nest Logit sind einige andere Vertreter. Grundsätzlich haben alle Modelle ihre Existenzberechtigung und ihre spezifischen Vor- und Nachteile. Auf die ausführliche Vorstellung dieser Modelle wird an dieser Stelle verzichtet (für weitere Informationen siehe u.a. Treiber 2018).

Ähnlich wie bei einer linearen Regressionsanalyse wird auch bei der logistischen Regression versucht, eine Funktion zu bestimmen, die sich möglichst gut an die vorliegenden Werte anpasst. Dies ist dann der Fall, wenn Werte für die Regressionskoeffizienten (siehe $\beta$ in Formel (8)) gefunden werden, mit denen die beobachteten Werte möglichst gut reproduziert werden können. Um lineare Regressionsmodelle statistisch zu schätzen, also die Funktionsparameter zu bestimmen, wird meist die Methode der kleinesten Quadrate (Least-Squares-Errors – LSE) genutzt. Bei Modellen der diskreten Wahltheorie kann diese aufgrund der Eigenschaften der logistischen Regression (z.B. Heteroskedastizität und Nicht-Linarität der Wahrscheinlichkeiten) jedoch nicht ohne weiteres genutzt werden, weil sie teils zu verzerrten und ineffizienten Schätzern führt. Daher wird für die Schätzung von

diskreten Wahlmodellen ein anderes Verfahren genutzt: die Maximum-Likelihood-Methode (kurz MLE für engl. Maximum-likelihood estimation) (Wolf und Best 2010).

Ziel der MLE ist es die Regressionskoeffizienten zu bestimmen, die eine möglichst gute Anpassung der Regressionsfunktion an die empirischen Daten erlauben. Dies ist dann der Fall, wenn für Beobachtungen mit $y_i = 1$ die Wahrscheinlichkeit $p(x)$ im Modell möglichst hoch ist (also möglichst nahe eins). Im Gegensatz dazu sollte die Wahrscheinlichkeit für Beobachtungen mit $y_i = 0$ möglichst gering, also die vorhergesagte Wahrscheinlichkeit möglichst nahe null sein (ebd.). Weitere methodische Ausführungen, wie bspw. die Herleitung der zu maximierenden Likelihood-Funktion oder die mathematische Formulierung der MLE können Treiber 2018 und Wolf und Best 2010 entnommen werden.

Ist ein Modell geschätzt, so können für die Bestimmung der Modell-Güte unterschiedliche Maßzahlen herangezogen werden. Mit einem Chi-Quadrat-Test kann bspw. überprüft werden, ob das ermittelte Regressionsmodell insgesamt signifikant ist – es also im Vergleich mit der modalen Vorhersage (es wird der Modalwert von der unabhängigen Variable vorhergesagt) insgesamt einen Erklärungsbeitrag leistet (Vgl. Backhaus, et al. 2016 und Wolf und Best 2010).

Darüber hinaus kann die Signifikanz der Regressionskoeffizienten ermittelt werden. Mittels eines Wald-Tests werden dabei die Regressionskoeffizienten jeweils einzeln getestet und auf Signifikanz geprüft (ebd.).

Für die Ermittlung der Modell-Güte können, analog zum Bestimmtheitsmaß bei der linearen Regression, sog. Pseudo-$R^2$ berechnet werden. Sie erlauben die Beurteilung der Modell-Güte. Drei häufig genutzte Pseudo-$R^2$ sind das McFadden-$R^2$, das Cox&Snell-$R^2$ und das Nagelkerke-$R^2$ (ebd.).

Eine weitere Möglichkeit die Güte des Modells zu bewerten besteht darin, die vorhergesagten Werte den beobachteten Werten gegenüberzustellen. Dafür werden die von der Regressionsfunktion berechneten Wahrscheinlichkeiten genutzt und die binären Werte – also bspw. Wahl (1) oder nicht Wahl (0) einer Route – bestimmt, um sie anschließend den beobachteten Werten gegenüberzustellen und einen Prozentsatz der richtig vorhergesagten Werte zu bestimmen (ebd.).

Mit den genannten Verfahren stehen eine Vielzahl von Maßen und Methoden zur Verfügung, die für die Einschätzung der Modell-Güte genutzt werden können. Die für die vorliegende Arbeit genutzten Verfahren werden in Kapitel 4.3 ausführlich beschrieben.

### 2.2.3 Verkehrsangebot und Verkehrsnachfrage

Um Entscheidungen des Verkehrsverhaltens zu untersuchen und Zusammenhänge aufdecken zu können, bedarf es ausreichend genauer Daten zum Verkehrsangebot und zur Verkehrsnachfrage.

**Verkehrsangebot**

In der Verkehrsplanung wird unter dem Begriff Verkehrsangebot die gesamte verkehrstechnische und -organisatorische Ausgestaltung eines Verkehrssystems verstanden, die Ortsveränderungen ermöglicht (Winkler 2011). Das Verkehrsangebot setzt sich aus einer Vielzahl von unterschiedlichen Elementen zusammen. Zu diesen Elementen gehören neben der Verkehrsinfrastruktur, bestehend aus Verkehrsnetzen (z.B. Straßen oder Schienen), Verknüpfungspunkten (z.B. Bahnhöfe oder Haltestellen) und Steuerungseinrichtungen (z.B. Lichtsignalanlagen und Verkehrsleitsysteme) auch die zur Verfügung stehenden Verkehrsmittel (z.B. Pkw, Busse, Züge, Fahrräder) sowie die organisatorischen, technischen und rechtlichen Rahmenbedingungen, die die Erbringung von Leistungen ermöglichen (z.B. Fahrpläne oder Verkehrsregeln). Das Verkehrsangebot kann sich zwischen verschiedenen geographischen Räumen unterscheiden und im zeitlichen Verlauf ändern (Rodrigue 2020).

Wichtige Einflussfaktoren der Inanspruchnahme bzw. Auslastung eines Verkehrsangebots sind die Eigenschaften des Angebots selbst. Sie werden meist in Form von Aufwänden (z.B. Reisezeiten oder Kosten einer Alternative) spezifiziert und stellen eine wichtige Grundlage der Wahlentscheidungen (z.B. für Verkehrsmittel oder Routen) dar. Um die benötigten Aufwände, die für die Analyse und Modellierung von Entscheidungen benötigt werden, zu ermitteln, werden Verkehrsangebotsmodelle genutzt (Winkler 2011). Sie *„bilden [...] die Verkehrsnetze der Verkehrsarten mit ihren spezifischen Eigenschaften ab“* (Schiller 2013) und stellen die räumlichen sowie zeitlichen Strukturen eines Verkehrsangebots der unterschiedlichen Verkehrsmittel für einen definierten Untersuchungsraum dar. Dafür werden meist sogenannte Netzmodelle genutzt, die ein elementarer Bestandteil der Verkehrsangebotsmodellierung sind. Das Angebot wird in derartigen Modellen zwar stets vereinfacht bzw. schematisiert dargestellt, *„jedoch in einem so hinreichend genauen Detaillierungsgrad, wie es für den jeweiligen Planungsgegenstand notwendig ist“* (Winkler 2011).

Um das Verkehrsangebot in einem Modell abbilden zu können, müssen all seine wesentlichen Elemente abgebildet werden. Dazu können unterschiedliche Methoden ge-

nutzt werden. Zur Beschreibung von Verkehrsnetzen wird meist die Graphentheorie verwendet (weitere Informationen dazu siehe Knödel 2012), die ein adäquates mathematisches Werkzeug zur Beschreibung der Verkehrsnetze unterschiedlicher Verkehrsarten ist. Zudem kann sie um weitere Methoden (z.B. Geographische Informationssysteme oder Datenbanksysteme) ergänzt werden.

Verkehrsangebots- bzw. Netzmodelle bestehen in der Regel aus Kanten, Knoten und Zellen, die das Verkehrsnetz mit seinen Eigenschaften darstellen. Den im Netz existierenden Knoten, Kanten und Zellen sind Attribute zugeordnet, die zugewiesen und verändert werden können. Kanten stellen meist Strecken im Netz dar (z.B. Straßen) und können mit einer Vielzahl unterschiedlicher Attribute belegt werden. Längen, zulässige Verkehrssysteme und Fahrtrichtungen, als auch Kapazitäten oder zulässige Höchstgeschwindigkeiten sind typische Kantenattribute. Knoten stellen im Netzmodell Verbindungen zwischen Kanten dar und können dementsprechenden mit Attributen belegt werden (z.B. Übergangszeiten zwischen Verkehrsmodi oder Wartezeiten an Knotenpunkten). Darüber hinaus können Kanten und Knoten als sog. „Füllknoten“ bzw. „Füllkannten“ genutzt werden. Das sind Knoten bzw. Kanten, in denen Fahrten – also Ortsveränderungen – in einem Verkehrsnetzmodell beginnen oder enden. Sie stellen damit die Quell- und Zielorte von Fahrten im Netz dar. Über sie kann die Verkehrsnachfrage eines Verkehrssystems auf das Netz umgelegt werden (Schnabel und Lohse 2011). Neben Knoten und Kanten existieren in einem Angebotsnetz meist Verkehrszellen. Zellen sind im Verkehrsnetz flächenhafte Objekte, denen meist flächenhafte Attribute (z.B. Flächennutzung) zugeordnet werden. Sie können jedoch ebenso zur Datenverknüpfung genutzt (z.B. um Quell- oder Zielverkehrsaufkommen in das Verkehrsnetz einzuspeisen) werden (Winkler 2011).

Netzmodelle werden hauptsächlich für zwei Sachverhalte genutzt: a) um bewertungsrelevante Aufwände, die bei der Überwindung von Netzelementen entstehen, zu quantifizieren und b) um eine berechnete Verkehrsnachfrage auf das Angebotsnetz umzulegen. Im Rahmen der vorliegenden Arbeit ist vor allem a) relevant, da für die Analyse der Routenwahl möglichst alle relevanten Attribute aufbereitet und in einem Netzmodell hinterlegt werden müssen. Über die Verknüpfung der erhobenen GPS-Routendaten mit dem Netzmodell können schließlich die Eigenschaften bzw. Aufwände der gewählten Routen bestimmt werden und in die Modellschätzung einfließen (siehe Kapitel 4.2). Das Angebotsmodell und seine, mit allen erforderlichen Attributen belegten, Netzelemente sind von hoher Bedeutung, weil nur so die relevanten Aufwände bestimmt und in die Analyse integriert werden können.

**Verkehrsnachfrage**

Die Verkehrsnachfrage kann als das Gegenstück zum Verkehrsangebot verstanden werden. Nachfrage kann als die Inanspruchnahme eines Angebots und damit die Befriedigung von Bedürfnissen definiert werden (Piekenbrock 2020). Auf den Verkehrssektor übertragen bedeutet das, dass Verkehrsnachfrage die Nutzung eines Verkehrsangebots (z.B. die Nutzung eines Verkehrsmittels oder Wahl einer Route) darstellt, wodurch Menschen ihr Bedürfnisse nach Ortsveränderungen befriedigen. Verkehrsnachfrage entsteht also, wenn das Bedürfnis von Menschen mit einem vorhandenen Angebot gedeckt wird (Rodrigue 2020).

Die Verkehrsnachfrage weist bestimmte Charakteristika auf (z.B. räumliche und zeitliche Verteilung von Fahrten oder modale Aufteilung). Um die Verkehrsnachfrage zu analysieren und ihre Zustände räumlich abbilden zu können, werden Verkehrsnachfragemodelle verwendet. Mit ihnen können alle wichtigen Teilprozesse von Ortsveränderungen erfasst und beschrieben werden. Aus Gründen des Umfangs soll nicht weiter auf alle Teilprozesse der Nachfragemodellierung eingegangen werden. Der Vollständigkeit halber sind in Abbildung *6* jedoch die wichtigen Teilprozesse der Nachfragemodellierung dargestellt, die sich meist in dem klassischen 4-Stufenmodell wiederspiegeln.

Abbildung 6: Die vier Stufen der Verkehrsnachfragmodellierung (links die Stufe; rechts das Ergebnis)

Für die vorliegende Arbeit ist vor allem die letzte Stufe (Verkehrsumlegung) von großer Relevanz, da die Thematik der Routenwahl in diese Stufe eingebettet ist und zudem eng mit dem Angebotsnetz verknüpft ist. In der vierten Stufe der Verkehrsnachfragemodellierung erfolgt die Zuordnung der berechneten Verkehrsströme eines Verkehrsmittels (z.B. Fahrrad) zur jeweiligen Verkehrsinfrastruktur im Verkehrsangebotsnetz. In diesem Schritt wird die Routenwahl der Verkehrsteilnehmer ermittelt und schließlich die Gesamtbelastung des Verkehrsangebotsnetzes (z.B. Verkehrsmengen auf den Strecken) berech-

net (Schnabel und Lohse 2011). In Bezug auf die Routenwahl ist diese Stufe der Verkehrsnachfragemodellierung also relevant, weil mit Routenwahlmodellen, die die Routenwahl realistisch abbilden können, die Wirkung eines veränderten Verkehrsangebots (bspw. einer neuen Führungsform auf einer Strecke) abgeschätzt werden kann. Dazu werden in einem ersten Schritt Routenalternativen für jede Fahrt bzw. je Quelle-Ziel-Relation erzeugt, mit einem (Routenwahl-) Modell bewertet und die Fahrten je Quelle-Ziel-Relation entsprechend der Wahlwahrscheinlichkeiten aufgeteilt. Ein Routenwahlmodell, das Routenalternativen realistisch bewertet, ermöglicht realitätsnahe Prognosen bzgl. der Infrastrukturnutzung und damit die effiziente und effektive Umsetzung von Maßnahmen in der Verkehrsplanung (siehe Kapitel 2.1.3).

### 2.2.4 Routensuchverfahren

Um die Routenwahl mit Verfahren der diskreten Wahltheorie (siehe Kapitel 2.2.2) zu analysieren, werden den gewählten Originalrouten nicht gewählte Routenalternativen gegenübergestellt. Dazu müssen zunächst mögliche Routenalternativen zwischen dem Quell- und Zielort einer Fahrt erzeugt werden. Routensuchverfahren sind daher nicht nur ein wesentlicher Bestandteil der Verkehrsumlegung (vgl. Kapitel 2.2.3), sondern auch eine Methode, die für die Analyse der Routenwahl genutzt werden muss, wenn RP-Daten zu gewählten Routen vorliegen (z.B. GPS-basierte Trajektorien).

Für die Erstellung von Routenalternativen sind ein Verkehrsangebots- bzw. Netzmodell (siehe Kapitel 2.2.3) sowie Routensuchverfahren notwendig, mit denen in dem Netzmodell potentiell genutzte Routen gefunden werden können. Für diesen Prozess, der auch Fahrtwegermittlung genannt wird, stehen eine Vielzahl von unterschiedlichen Verfahren zur Verfügung. Sie lassen sich grundlegend in Best-Weg-Verfahren und Mehr-Weg-/Alternativ-Verfahren unterteilen (Schnabel und Lohse 2011).

Beim Best-Weg-Verfahren (auch Optimal-Routensuch-Verfahren genannt) wird aus einer Vielzahl von Möglichkeiten der optimale bzw. beste Weg zwischen einer Quelle und einem Ziel gesucht. Es wird dabei die Route ermittelt, für die der Widerstand bzw. der Aufwand (z.B. Reisezeit) auf der Quelle-Ziel-Relation minimal ist. Zur Ermittlung der Routen stehen unterschiedliche mathematische Algorithmen zur Verfügung (z.B. Dijkstra-Algorithmus, Moor'sche Algorithmus) (ebd.).

Bei Mehrweg- bzw. Alternativ-Verfahren werden im Gegensatz zum Best-Weg-Verfahren mehrere Routen aus der Gesamtheit möglicher Alternativen bestimmt. Dabei erfolgt die Suche sinnvoller Routen durch die Bewertung der Wege hinsichtlich unterschiedlicher

Attribute (z.B. Reisezeit, Distanz, Wartezeiten oder baulicher Zustand). Zwar können mit diesem Verfahren sehr viele mögliche Routen gefunden werden, doch ist es auch möglich, dass wenig relevante Alternativen gefunden werden oder dass Teilstücke eines Weges mehreren Wegen angehören. Routen können so teils starke Ähnlichkeit aufweisen. Das Ergebnis hängt bei den Verfahren stark von den definierten Suchkriterien ab. Auch der Best-Weg kann zu den gefundenen Routen gehören. Resultat des Verfahrens ist ein sog. *Choice Set*, dass verschiedene Routen mit unterschiedlichen Aufwänden zwischen einer Quelle und einem Ziel enthält (ebd.).

Bei den Mehr-Weg-Verfahren kann grundlegend zwischen zwei Verfahren unterschieden werden: a) deterministische und b) stochastische Verfahren. Bei deterministischen Verfahren wird jeweils der kürzeste, der zweit-kürzeste, bis hin zum n-kürzesten Weg gesucht. Damit sinnvolle Wege gefunden werden, sind Prüfverfahren notwendig, mit deren Hilfe die Einhaltung bestimmter Bedingungen kontrolliert werden kann (z.B. Prüfung von Wegen bzgl. ihrer praktischen Relevanz in Bezug auf den Best-Weg). Dazu dienen bspw. Wegelänge- oder Schleifen-Tests. Beim Wegelänge-Test wird ein Wegelängen-Faktor berechnet, der den Umweg gegenüber dem kürzesten Weg indiziert (in Städten bspw. $WF_K = 1{,}4$). Beim Schleifen-Test wird hingegen untersucht, ob bei Routen, die einen gemeinsamen Verlauf besitzen, die Abweichung (Schleife) von einem kürzeren Teilweg einen sinnvollen Verlauf ergibt (ebd.).

Bei stochastischen Verfahren werden mehrere Alternativen gebildet und diese auf den Anteil gemeinsamer Teilwege hin analysiert. Dies ist sinnvoll, da bei einer übermäßig starken Überlappung von Alternativrouten eigentlich nicht mehr von Alternativen, sondern eher von Varianten einer Route gesprochen werden muss (Schnabel und Lohse 2011). Dieser Sachverhalt, der in der Theorie als IIA-Eigenschaft (engl. *Independence of Irrelevant Alternatives*) bezeichnet wird, muss bei der Analyse und Modellierung der Routenwahl besondere Beachtung finden. Die IIA kann in einem einfachen Beispiel dargestellt werden (siehe Abbildung *7*).

Zwischen Quelle und Ziel existieren drei mögliche Routen, wobei die Aufwände der Routen jeweils 1 betragen. Ist $x = 1$, so existiert bei den unteren Routen kein gemeinsamer Streckenanteil und es ergeben sich damit drei unterschiedliche Routen, deren Wahlwahrscheinlichkeit jeweils 1/3 ist. Verringert sich jedoch $x$, so steigt der gemeinsame Streckenanteil der beiden unteren Routen und die Ähnlichkeit der beiden Routen wird größer. Ist $x = 0$, dann verbleibt lediglich der gemeinsame Streckenteil, sodass sich die beiden Routen zu einer vereinen. Aus diesem Grund müsste die Wahlwahrscheinlichkeit der (beiden) unteren und der oberen Route jeweils 1/2 betragen. In dem Beispiel ergäben sich bei der

Anwendung eines Modells mit IIA-Eigenschaft (z.B. Logit-Modell) in dem Beispiel bei *x = 0* jedoch Wahlwahrscheinlichkeiten von 1/3 je Route. Es handelt sich dabei also um einen Fehler, der bei einer Nichtberücksichtigung der Ähnlichkeit (z.B. gemeinsame Routenabschnitte) von Routenalternativen entsteht (Schnabel und Lohse 2011).

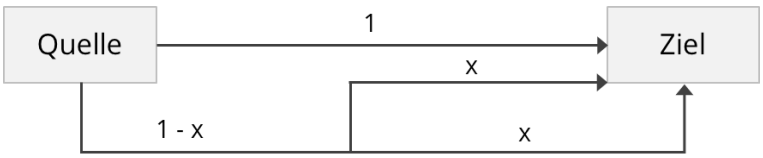


Abbildung 7: Beispiel zur Erläuterung der IIA-Eigenschaft
(Eigene Darstellung nach Schnabel und Lohse 2011)

Dem Problem kann durch die Analyse und Unterscheidung gemeinsamer Teilwege von Routen entgegengewirkt werden. Dazu schlagen bspw. Schnabel und Lohse 2011 vor, den gemeinsamen Wegeanteil nach

$$AVF_{K,q} = \frac{TW_{K,q}}{W_K} \tag{10}$$

mit $TW_{K,q}$ als Widerstand des Teilweges und $W_K$ als Widerstand des Gesamtwegs, zu berechnen. Eine Route *q* ist demnach eine Alternative ggü. Weg *k*, wenn $AVF \geq 0{,}5$. Das bedeutet, eine Route *q* und *k* werden max. auf 50 % des Weges gemeinsam geführt. Ist $AVF < 0{,}5$, dann ist eine Route *q* eine Variante von Route *k* und keine echte Alternative (Schnabel und Lohse 2011). Darüber hinaus existieren Modelle, die mit Hilfe eines Ähnlichkeitsmaßes, einem sog. *communality factor*, gemeinsam genutzte Routenabschnitte beachten und sie in das Modell integrieren, um den geschilderten Fehler zu vermeiden (bspw. das C-Logit von Cascetta 2001).

Wurden mittels Routensuchverfahren mehrere Routenalternativen gefunden, so können diese mit Attributen aus dem Netzmodell angereichert werden. Die attribuierten Routenalternativen können anschließend für a) die statistische Schätzung von Routenwahlmodellen oder b) die Bewertung von Routenalternativen im Rahmen der Verkehrsumlegung genutzt werden.

## 2.3 GPS-Daten zum Radverkehr

In den folgenden Abschnitten soll ein grundlegendes Verständnis für die Funktionsweise des Global Positioning System (GPS) gegeben werden, weil GPS-Daten eine wichtige Datengrundlage der vorliegenden Arbeit sind. Dabei sind neben der Funktionsweise

selbst vor allem die Grenzen des Systems relevant, die sich aus der Funktionsweise ergeben und einen erheblichen Einfluss auf das methodische Vorgehen der Datenaufbereitung haben.

Darüber hinaus soll ein Überblick über bereits vorhandene GPS-Daten zum Radverkehr gegeben und deren Eignung für die Zwecke der vorliegenden Arbeit näher beleuchtet werden.

### 2.3.1 Global Positioning System – GPS

Globale Satellitennavigationssysteme sind Systeme, die zur weltweiten Positionsbestimmung und Navigation genutzt werden können. Es existieren mehrere der sogenannten GNSS (engl.: *global navigation satellite systems*). Das *"Navigational Satellite Timing and Ranging Global Positioning System"* (kurz: NAVSTAR GPS) war das erste und ist das weltweit meist genutzte Ortungssystem (El-Rabbany 2002). Es handelt sich dabei um ein Satelliten-basiertes Ortungssystem, das vom US Verteidigungsministerium in den 1970er Jahren entwickelt wurde und das sich seit Juli 1995 mit seiner vollumfänglichen Betriebskapazität in Anwendung befindet (NASA 2017). Es steht seit Mai 2000 auch für die zivile Nutzung in voller Qualität zur Verfügung und wird weltweit für zahlreiche Navigationsdienste und mobile Anwendungen genutzt (Rötzer 2000). Andere Systeme, wie bspw. das russische GLONASS oder das europäische GALILEO, spielen vor allem in der zivilen Nutzung derzeit eine untergeordnete Rolle.

Die Funktionsweise aller GNSS folgt einem ähnlichen Prinzip. Sie wird im Folgenden beispielhaft für das NAVSTAR GPS beschrieben. Die Systeme bestehen aus drei unterschiedlichen Segmenten (siehe Tabelle *1*), die in Kombination über das Prinzip des sogenannten „einfachen Bogenschlags" die Positionsbestimmung ermöglichen.

| | **Weltraum-Segment** | **Kontroll-Segment** | **Nutzer-Segment** |
|---|---|---|---|
| **Komponenten** | • min. 24 Satelliten<br>• Entfernung zur Erdoberfläche ca. 20.000 km<br>• Erdumrundung alle 12h<br>• hochgenaue Atomuhren für die Bestimmung der Signallaufzeit | • 5 Monitoring-Stationen<br>• 4 Telemetrie-Stationen<br>• Master Control Station in Colorado Springs (USA) | • GPS-Empfänger ziviler und militärischer Nutzer |
| **Funktion** | • Satelliten senden permanent Trägerwellen aus (abgeleitet aus der Grundfrequenz, die von der Atomuhr generiert wird) | • Überwachung der Atomuhren in den Satelliten und des Gesamtsystems<br>• Prüfen atmosphärischer Daten etc. | • Empfang der GPS-Signale<br>• Positionsbestimmung |

Tabelle 1: GNSS-Segmente und ihre Eigenschaften (Eigene Darstellung nach NASA 2008 und NASA 2017)

Die Idee dieses Prinzips ist simpel: Ist die Entfernung zu drei Punkten relativ zur eigenen Position bekannt, so kann über trigonometrische Verfahren die eigene Position im Verhältnis zu diesen drei Punkten bestimmt werden. Zur Umsetzung des Prinzips senden die Satelliten ständig die aktuelle Position und die genaue Uhrzeit aus. Aus der Signalausbreitungsgeschwindigkeit und den Signallaufzeiten kann die Entfernung zwischen Empfänger und den unterschiedlichen Satelliten berechnet werden (El-Rabbany 2002).

Liegt eine Information zur Distanz zwischen dem Empfänger und einem Satelliten vor, so kann die Position des Empfängers an einem beliebigen Punkt auf der Kugelschale um den entsprechenden Satelliten liegen. Ist die Distanz zu einem zweiten Satelliten bekannt, so kann die Empfängerposition auf eine Kreisbahn eingegrenzt werden, die beim Schnitt der Kugelschalen der beiden Satelliten entsteht (siehe blau markierte Kreisbahn in Abbildung 8 a). Ist schließlich die Distanz zu einem dritten Satelliten gegeben, reduzieren sich die möglichen Positionen auf zwei Punkte auf der genannten Kreisbahn, weil die Kugel um den dritten Satelliten nur zwei Schnittpunkte mit dieser Kreisbahn haben kann (siehe rote Punkte in Abbildung 8 b). Mit der Distanz zu einem vierten Satelliten kann letztendlich eine eindeutige Zuordnung der Position zu einem der beiden Punkte erfolgen (siehe weißer Punkt mit roter Kontur in Abbildung 8 c). Weiterführende Beschreibungen zur Funktionsweise können in El-Rabbany 2002 und Hofmann-Wellenhof, B., Lichtenegger und Colli 2001 nachgeschlagen werden.

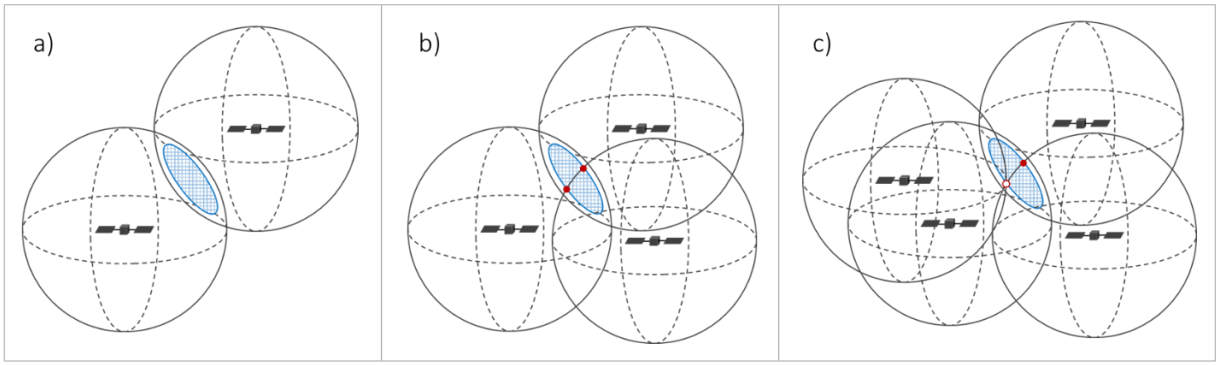


Abbildung 8: Prinzip der Positionsbestimmung mittels GNSS (Eigene Darstellung nach NASA 2008)

Das beschriebene NAVSTAR GPS lässt eine recht genaue Positionsbestimmung (± 15 m) zu. Dem System sind jedoch Grenzen bzgl. der Genauigkeit gesetzt, die im Wesentlichen auf systeminhärente Fehlerquellen zurückzuführen sind. So kann es bspw. zu Signallaufzeitverzögerungen kommen, wenn Luftschichten mit unterschiedlichen Dichten oder Luftfeuchtigkeit in der Atmosphäre vorherrschen und dadurch das Satellitensignal gebrochen wird. Darüber hinaus können kleinere Abweichungen der Satelliten- und Emp-

fängeruhren zu einer Verzerrung der Laufzeitmessung und damit zu Fehlern in der Distanzberechnung führen. Weitere Fehlerquellen bestehen in dem sogenannten Mehrwegeeffekt. Darunter versteht man die Reflektion der Signale an großen reflektierenden Oberflächen wie bspw. Gebäuden, die zu einer Verlängerung der Signallaufzeit führen. Daneben existiert noch die sog. *Dilution of Precision*, bei der sich die Genauigkeit verringert, wenn die Satelliten ungünstig zueinander positioniert sind. Tiefergehende Informationen zu Potentialen und Grenzen des Systems sind in NASA 2008 beschrieben.

### 2.3.2 Nutzen von GPS-Daten für die Radverkehrsplanung und -forschung

Mit dem zunehmenden technischen Fortschritt sowie der ansteigenden Verbreitung von GPS-fähigen Endgeräten (z.B. Smartphones) und entsprechenden Anwendungen (Apps) ist in der letzten Dekade das Aufzeichnen von GPS-Daten zunehmend einfacher geworden. Dies hat zur Folge, dass auch immer mehr Radfahrende ihre Fahrten aus unterschiedlichen Motiven aufzeichnen. Die aufgezeichneten Daten haben einen hohen Informationsgehalt und können der Verkehrsplanung prinzipiell sehr detaillierte Informationen liefern (z.B. zu den gewählten Routen oder zur räumlichen Verteilung des Radverkehrs in einer Stadt).

Eine wesentliche Methode zur Datengewinnung wird als *Crowdsourcing* bezeichnet. Bei *Crowdsourcing* handelt es sich um Ansätze, bei denen die Daten von der eigentlich zu beobachtenden Menge von Menschen (*Crowd*) selbst erhoben werden (*sourcing*). Die Datenerhebung erfolgt bspw. via Smartphone-App, mit der die Teilnehmenden ihre gefahrenen Wege in Form von georeferenzierten Routendaten (GPS-Tracks) aufnehmen und dem App-Anbieter übermitteln. Durch die Gesamtheit aller Daten lassen sich schließlich Rückschlüsse z.B. auf das Verkehrsverhalten der Radfahrenden ziehen (Smith, Fehr und Peers 2015).

Für die Erhebung selbst ist es zunächst unerheblich, welche Apps genutzt werden. In Deutschland sind prominente Anbieter solcher Apps bspw. Naviki, BikeCitizens, Strava oder Komoot, mit denen Nutzer*in ihre Bewegungsmuster aufzeichnen können. Die aufgezeichneten Fahrten werden schließlich an den App-Anbieter übermittelt, der alle verfügbaren Daten aufbereitet (ebd.). Die so erhobenen Daten können anschließend einen Überblick über die räumliche Ausprägung und Eigenschaften des Radverkehrs in den Städten geben. Weitere Einzelheiten zu Potentialen und Grenzen der angesprochenen Daten können Lißner und Francke 2017 entnommen werden.

Prinzipiell können derartige Daten den Wissenschaftler*innen und Planer*innen helfen, das Verkehrsverhalten von Radfahrenden zu untersuchen. Allerdings unterscheiden

sich die derzeit verfügbaren GPS-basierten Daten hinsichtlich ihrer Quantität und Qualität stark voneinander. Im Hinblick auf die Eignung derartiger Daten für die Untersuchung der Routenwahl müssen die vorhandenen Datenquellen differenziert betrachtet werden.

Datensätze, die auf erhobenen GPS-Daten von Radfahrenden basieren, sollten vor allem bzgl. der Anbieter, die Apps zur Datenaufzeichnung zur Verfügung stellen, differenziert werden, da sich die Motivation zur Datenaufzeichnung, und damit auch die Nutzung spezieller Apps, unterscheiden kann und sich auf die Ergebnisdaten selbst auswirken kann. Daten werden meist über Sport-Apps (z.B. Strava), Bike-Sharing-Systeme (z.B. Call a Bike), Navigations-Apps (z.B. BikeCitizens) oder über anderweitige und meist lokale Initiativen (z.B. Radwende Wiesbaden) erhoben. Die über diese Plattformen erhobenen Daten besitzen Eigenschaften, die sich für die Analyse des Radverkehrsverhaltens und der Routenwahl vor- bzw. nachteilig auswirken können (Lißner und Francke 2017).

Daten von Sport-App-Anbietern weisen teils eine sehr hohe räumliche Abdeckung auf; so erhebt der Anbieter *Strava* bspw. deutschlandweit GPS-Daten (Strava 2020). Die erhobenen und verarbeiteten Daten werden in aggregierter Form seit ein paar Jahren von dem App-Betreiber angeboten (Jestico, Nelson und Winters 2016). Stärken der Datengrundlage liegen vor allem in der hohen Anzahl von App-Nutzer*innen sowie darin, dass die Nutzer*innen eine hohe Eigenmotivation zur App-Nutzung aufweisen. Dies führt dazu, dass viele GPS-Tracks von den Nutzer*innen erhoben und an den Anbieter übertragen werden. Auf der anderen Seite muss beachtet werden, dass die Gruppe der Nutzenden sehr homogen (meist sportive Männer) und in den meisten Fällen nicht repräsentativ für alle Radfahrenden einer Stadt ist (vgl. Lißner und Francke 2017).

Eine weitere GPS-basierte Datenquelle für den Radverkehr sind Daten von Bike-Sharing-Anbietern wie bspw. *Call a Bike*, *Nextbike*, *Mobike* oder *LimeBike*. Im Vergleich zu Anbietern von Sport-Apps sind Daten von Bike-Sharing-Anbietern teils frei verfügbar (vgl. Connect 2020). Da Bike-Sharing mittlerweile deutschlandweit in vielen Großstädten angeboten wird, werden entsprechend viele Daten für diese Städte erhoben. Die größte Abdeckung ist derzeit durch das Unternehmen *Nextbike* gegeben, das in 57 deutschen Städten (Stand 2020) Räder zum Verleih anbietet (Nextbike 2020). Ein weiterer Anbieter mit weit verbreitetem Angebot ist *Call a Bike*, der in 43 Städten (Stand 2020) in Deutschland tätig ist (Call a Bike 2020). Beim den meisten Bike-Sharing-Anbietern werden beim Ausleih- und Abgabevorgang und teilweise auch während der Fahrt die Koordinaten mittels GPS-Sensoren ermittelt. Diese sind entweder direkt in den Leihrädern verbaut oder die GPS-Daten

werden mittels Smartphone und der App des Anbieters erhoben. Die Daten zu Ausleih- und Abgabeorten sind teils öffentlich zugänglich (vgl. Connect 2020).

Tracking- und Navigations-Apps, wie bspw. Apps der Anbieter *BikeCitizens*, *Naviki* oder *BBBike*, sind eine weitere potentielle Datenquelle (Lißner und Francke 2017). Radfahrende können diese Apps einerseits dazu nutzen, um sich von einem Ort zu einem anderen navigieren zu lassen. Anderseits können sie ihre Strecken mit entpsrechenden Apps aufzeichnen. Dementsprechend werden in all jenen Städten Daten erhoben, in denen die entsprechenden Apps genutzt werden. Die räumliche Abdeckung kann je nach Anbieter und Region sehr unterschiedlich ausfallen. Die Gruppe der App-Nutzenden scheint deutlich weniger homogen zu sein als jene von Apps mit sportivem Hintergrund. Da die Anwender die Apps häufig zum Navigieren nutzen, spiegeln die aufgezeichneten Daten jedoch nicht zwangsläufig das natürliche und unbeeinflusste Verkehrsverhalten der Radfahrenden wider. Dies trifft im Besonderen auf die Wahl ihrer Route zu. Nach Aberle und Pühringer 2017 wurden bspw. rund 60% aller Nutzer*innen der *BikeCitizens*-App navigiert.

| **Datenquelle** | **Stärken** | **Schwächen** | **Beispiel** |
|---|---|---|---|
| Sport-Apps | • großflächige räumliche Abdeckung<br>• teils Daten für mehrere Jahre verfügbar<br>• viele Nutzer*innen mit hoher Nutzungsintensität (dadurch viele Daten) | • sehr homogene Nutzergruppe<br>• Daten nicht frei verfügbar<br>• Qualität & Transparenz der Datenverarbeitung | • Strava |
| Bike-Sharing | • Abdeckung der meisten deutschen Großstädte<br>• heterogene Nutzergruppe<br>• Daten teils frei verfügbar | • Nutzer*innen entsprechen eher nicht Alltagsradfahrenden<br>• keine Informationen zu den Routen<br>• keine Informationen zu den Nutzer*innen | • Call a Bike<br>• Nextbike<br>• Ofo<br>• Mobike |
| Navigations-Apps | • eher heterogene Nutzergruppe | • meist wenige Fahrten von Einzelnutzer*innen<br>• Routing verfälscht das Fahrverhalten<br>• Daten stehen nicht frei zur Verfügung | • BikeCitizens<br>• Naviki<br>• BBBike |
| Lokale Initiativen | • Lokale Verwurzelung schafft Verständnis und Teilnahmebereitschaft<br>• kann überall durchgeführt werden | • meist nur lokale Abdeckung<br>• Daten nicht frei verfügbar<br>• Informationskanäle entscheiden über STP-Zusammensetzung | • Radwende Wiesbaden |

Tabelle 2: Stärken und Schwächen der unterschiedlichen GPS-basierten Daten

Über die genannten Quellen hinaus existieren weitere Möglichkeiten, GPS-basierte Daten für die Planung zu nutzen. Lokale Initiativen, wie bspw. die „Radwende“ in Wiesbaden, sind meist tief in der Stadt oder Region verwurzelt und erreichen so ein breites Teilnehmerfeld und eine hohe Akzeptanz in der lokalen Bevölkerung (Lazarescu 2020). Sie können prinzipiell überall durchgeführt werden, bedürfen jedoch großer Anstrengungen für die Umsetzung. Daten solcher Initiativen sind jedoch nicht flächendeckend verfügbar. Die erhobenen Daten können mit entsprechendem Know-how ausgewertet und für die Planung genutzt werden. Tabelle *2* fasst die beschriebenen Datenquellen noch einmal überblicksartig zusammen und stellt Stärken und Schwächen der Ansätze heraus.

GPS-Daten sind grundsätzlich sehr gut geeignet, um die Routenwahl von Radfahrenden zu analysieren, da sie die gefahrenen Strecken der Radfahrenden mit hoher Genauigkeit aufzeichnen und damit räumlich exakt verorten.

Da aus datenschutzrechtlichen und unternehmerischen Gründen jedoch keine einzelnen Trajektorien (GPS-Tracks) der Radfahrenden weitergegeben oder veräußert werden, sondern nur Informationen in aggregierter Form zur Verfügung gestellt werden (vgl. Strava), lassen sich aus diesen Informationen keine Einzelrouten der Radfahrenden nachvollziehen. Auch anderweitige Datenquellen, wie bspw. den Daten von *Call a bike*, bieten keine Informationen zu den genutzten Routen, da lediglich Quellen und Ziele der Fahrten bekannt sind und keine Informationen zu den zurückgelegten Routen und genutzten Strecken vorliegen. GPS-Datenquellen, die auf Routing basieren (bspw. *Bike Citizens* oder *Naviki*) sollten für eine Abschätzung der Routenwahl und ihrer Einflussfaktoren generell nicht genutzt werden, da die Radfahrenden während der Fahrt navigiert wurden. Das Verhalten der Radfahrenden entspricht daher nicht der unbeeinflussten Routenwahl.

Es lässt sich resümieren, dass die Quantität und Qualität der beschriebenen Daten unterschiedlich ausfällt. Die Räumliche Abdeckung variiert ebenso wie die Intention der Datenerhebung durch die Anbieter und App-Nutzer*innen, was sich stark auf die Nutzbarkeit derartiger Daten auswirkt. Um das Routenwahlverhalten von Radfahrenden und seine Einflüsse abbilden und analysieren zu können, sind GPS-Trajektorien der einzelnen Fahrten von den Radfahrenden notwendig, die das Fahrverhalten frei von Einflüssen abbilden.

## 2.4 Zusammenfassung

In dem vorliegenden Kapitel wurde aufgezeigt, dass der Radverkehr in Deutschland von zunehmender Bedeutung ist. Um dessen Vorteile zu nutzen und seine Potentiale zu heben, ist eine gezielte Radverkehrsförderung notwendig, die durch eine effektive Planung gewährleistet werden kann. Für die Planung eines an der Radverkehrsnachfrage orientierten Verkehrsangebots bedarf es zum einen Wissen zu Routenwahlpräferenzen der Radfahrenden. Darüber hinaus kann die Analyse der Routenwahl mittels geeigneter Verfahren dazu beitragen, Routenwahlentscheidungen zu quantifizieren. Die resultierenden Modelle können wiederum in der Verkehrsplanung eingesetzt werden und so zu einer Verbesserung der Radverkehrsinfrastruktur beitragen. Für die Analyse, und eine später möglichst realistische Abbildung des Radverkehrsverhalten in den Modellen, werden Daten zum real-beobachteten Routenwahlverhalten von Radfahrenden benötigt. Es wurde verdeutlicht, dass im Radverkehr zunehmend GPS-Daten erhoben werden, die Auskunft über die genutzten Routen im Radverkehr geben. Quantität und Qualität der Daten können in Abhängigkeit der Datenquelle jedoch stark variieren. Aus dem nachfolgenden Kapitel wird ersichtlich, wie GPS-basierte Radverkehrsdaten im Rahmen von Forschungsarbeiten zur Analyse der Routenwahl bereits genutzt wurden.

# 3. Forschungsstand

Es wurden bereits zahlreiche Studien zur Untersuchung der Routenwahl von Radfahrenden durchgeführt. Dabei wurde in den letzten Jahrzehnten zunehmend versucht, die unterschiedlichen Faktoren und deren Einfluss auf die Routenwahl zu identifizieren und zu quantifizieren. In den folgenden Abschnitten wird ein umfassender Überblick über den Stand der Forschung gegeben. Zunächst wird die Methodik der Literaturrecherche vorgestellt. Anschließend werden die Forschungsarbeiten präsentiert, welche die Routenwahl von Radfahrenden auf Basis von RP-Daten mit Methoden der multivariaten Statistik untersucht haben.

## 3.1 Methodik der Literaturrecherche

Um den Stand der Forschung im Rahmen einer umfassenden Literaturrecherche zu beleuchten, können unterschiedliche qualitative und quantitative Methoden herangezogen werden (Cooper 1989). Deren individuellen Vor- und Nachteile wurden in der Literatur bereits umfassend beschrieben und können bspw. bei Li und Cavusgil 1995, Whittemore und Knafl 2005 oder Cronin, Ryan und Coughlan 2008 nachgeschlagen werden.

Um möglichst alle relevante Literatur zum Thema zu recherchieren, wurden zwei komplementäre und sich ergänzende Methoden für die Recherche genutzt, die sich bereits in zahlreichen Studien als adäquat herausgestellt haben. Zum einen wurde die eher quantitative und systematische Literaturrecherche angewendet. Zum anderen die eher qualitative Methode des „Vererbungs-Prinzips“ genutzt.

Die systematische Literaturrecherche ist eine geeignete Methode um möglichst viele Studien zum Thema zu recherchieren. Zur Durchführung der systematischen Recherche wurde eine computerbasierte Suche auf Basis unterschiedlicher Literaturdatenbanken durchgeführt. Sie ist schnell und einfach durchzuführen, die Literaturdatenbanken umfassen meist alle wesentlichen wissenschaftlichen Studien und die gefundene Literatur kann effizient gehandhabt werden.

Im Rahmen der Recherche erfolgte der Zugriff auf die Portale und Literaturdatenbanken des *Web of Science*, der *Transportation Research Information Database* (TRID), den SLUB-Katalog, die Literaturdatenbank des *Fahrradportals* vom Nationalen Radverkehrsplan des Bundesministeriums für Verkehr und digitale Infrastruktur (BMVI), des *WISO* sowie auf *ScienceDirect*. Die benannten Portale bieten einzeln sowie in Kombination eine sehr große

Abdeckung von Literatur und sind anerkannte Anlaufstellen für Recherche und Bezug wissenschaftlicher Literatur.

Im Rahmen einer systematischen Recherche ist die Auswahl geeigneter Stichworte für die Suche und Identifikation relevanter Studien wichtig. Für die Recherche der in Kapitel 3.2 beschriebenen Studien wurden die folgenden Stichworte genutzt:

- Radverkehr
- Routenwahl
- bicycle
- bike
- route
- choice
- GPS data

Die einzelnen Stichworte wurden bei der jeweiligen Suche in unterschiedlichen Kombinationen (Ein- sowie Ausschluss von Stichworten) verwendet.

Die Recherche wurde auf Deutsch und Englisch sowie in deutsch- und englischsprachigen Portalen durchgeführt. Da die Routenwahl im Radverkehr bisher vor allem international erforscht wurde, sind die meisten Publikationen zum Thema in englischer Sprache erschienen. Aus diesem Grund wurden im Rahmen der Recherche die größten Erfolge bei der Eingabe von englischen Stichworten erzielt. Die Nutzung deutscher Suchbegriffe auf den internationalen Plattformen ergab, wie erwartet, nur sehr wenige Treffer. Die Eingabe englischer Stichworte in deutschsprachigen Portalen führte hingegen oft zu vielen Treffern bzgl. englischsprachiger Literatur.

Im Laufe der Stichwortsuche wurden teilweise Filter genutzt, um die Suchergebnisse einzugrenzen. Presseartikel oder Firmeninformationen, wie sie bspw. im *WISO*-Portal zu finden sind, wurden herausgefiltert, weil sie oft keinen Mehrwert zur Aufarbeitung des Forschungsstands darstellten. Wurden bei einer Suche sehr viele Treffer erzielt, so wurden zusätzliche Filter verwendet (z.B. lediglich Bücher, Artikel aus Fachzeitschriften, Fallstudien, Leitfäden oder wissenschaftliche Arbeiten wie Promotionen). Darüber hinaus wurden die Suchergebnisse bei sehr vielen Treffern nach Relevanz sortiert (jeweils abhängig vom Angebot des Portals). Eine zeitliche Eingrenzung von Literatur wurde nicht gewählt.

Da zahlreiche Arbeiten gefunden wurden, die nicht zweifelsfrei dem Thema zugeordnet werden konnten, wurden anschießend alle Suchergebnisse in einem mehrstufigen Verfahren gesichtet. In einer ersten Stufe erfolgte die Auswahl der Studien nach den In-

halten des jeweiligen Titels und des Abstracts. Damit konnte ein erster inhaltlicher Überblick über die Studien gewonnen werden. Schien die Publikationen aufgrund der Inhalte relevant für die vorliegende Arbeit, wurde die Publikation in die Datenbank relevanter Literatur aufgenommen (Stufe 1). In einer zweiten Stufe wurde jede in Stufe 1 aufgenommene Publikation gelesen und auf inhaltliche Relevanz hin überprüft. Wurden die Inhalte nach dem Lesen der Arbeiten als relevant eingestuft, so wurden sie für die Erarbeitung des Forschungsstands berücksichtigt (Stufe 2).

Da in den meisten der genutzten Datenbanken die gleichen Publikationen gelistet sind, kam es im Rahmen der Recherche sehr häufig zu Mehrfachnennungen von Literatur. Nach dem Beseitigen dieser Dopplungen blieben schließlich 48 relevante Studien zum Themenbereich „Analyse der Routenwahl mittels multivariater statistischer Verfahren" bestehen, die für die Aufarbeitung des Forschungsstands genutzt wurden. Abbildung 9 gibt einen Überblick über die genutzten Datenbanken sowie die Ergebnisse der beschriebenen Literaturrecherche.

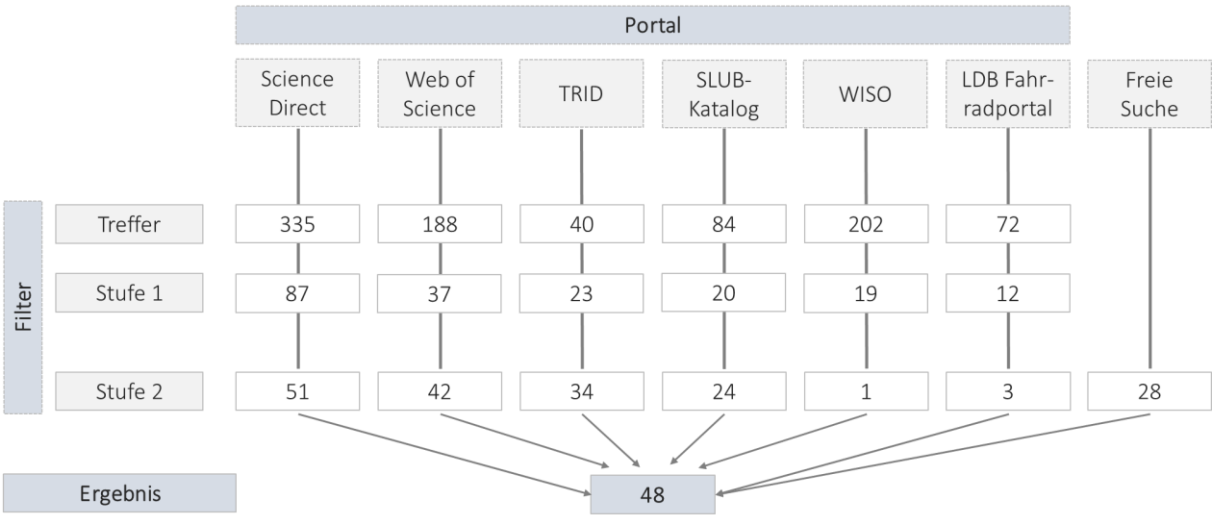


Abbildung 9: Übersicht der genutzten Literaturdatenbanken und Anzahl der recherchierten Studien

Neben der systematischen Literaturrecherche wurde zudem Literatur über das sogenannte „Vererbungs-Prinzip" und die „freie Suche" recherchiert. Unter „Vererbungs-Prinzip" ist die Identifikation von relevanter Literatur über zitierte Quellen in bereits vorliegenden Publikationen zu verstehen. Dabei wurde Zitationen und Quellen in Publikationen (zeitlich und thematisch) über mehrere „Generationen von Publikationen" hinweg gefolgt. Dies hat in einigen Fällen zur Identifikation weiterer Studien geführt. Bei der „freien Suche" wurden Suchmaschinen (wie bspw. Google) für die Recherche genutzt. Die beschriebene Literaturrecherche wurde initial im Jahr 2017 durchgeführt. Es erfolgte zudem eine Aktualisierung der Literatur im Jahr 2019.

## 3.2 Analyse der Routenwahl mittels multivariater statistischer Verfahren

In den meisten Studien wurden sog. *Stated Preference*-Experimente (SP) durchgeführt, in denen sich Teilnehmer*innen für eine Route aus einem vorgegebenen Set hypothetischer Alternativen mit unterschiedlichen Charakteristika entscheiden. SP-Experimente eignen sich gut, um Präferenzen von Proband*innen zu analysieren, die sich in der Realität nur schwer untersuchen lassen. Dies kann z.B. aufgrund fehlender Daten oder begrenzter Rechenkapazitäten der Fall sein. Zudem lassen sich einzelne Einflussfaktoren leicht separieren und der Einfluss von (noch) nicht existierenden Faktoren abschätzen. Durch die Nutzung von SP-Experimenten konnten bereits zahlreiche Erkenntnisse zur Routenwahl gewonnen werden (Hood, Sall und Charlton 2011). Die Erkenntnisse von Untersuchungen, die auf SP-Experimenten basieren, sind jedoch kritisch zu hinterfragen, weil Proband*innen befragt werden. Es fehlt jedoch eine Verifizierung der Ergebnisse durch die Beobachtung des tatsächlich realisierten Verhaltens – der sog. *Revealed Preference* (RP). Aus diesem Grund stehen in der vorliegenden Arbeit die Studien im Fokus, die auf Daten zum real beobachteten Verhalten basieren.

Die ersten Studien zur Untersuchung des Routenwahlverhaltens von Radfahrenden, die RP-Daten nutzten, wurden bereits in den 80er Jahren des 20. Jahrhunderts durchgeführt. Frühe Studien gehen dabei bis in das Jahr 1978 zurück (siehe Lott, Tardiff und Lott 1978) und reichen bis in die jüngste Vergangenheit (siehe Ghanayim und Bekhor 2018). Die seither entstandenen Arbeiten können vor allem hinsichtlich ihrer Auswertungsmethoden unterschieden werden. Viele Studien führen rein deskriptive Analysen durch, die zwar einen Überblick über genutzte Routen und ihre Eigenschaften geben können, jedoch keine Aussagen über kausale Zusammenhänge zulassen. Aus diesem Grund werden Studien mit rein deskriptiver Auswertung im Folgenden nicht weiter behandelt. Der Fokus liegt demzufolge auf Studien, die multivariate Analyseverfahren angewendet haben, um die Kausalitäten der Routenwahl zu bestimmen.

Es existiert eine Vielzahl entsprechender Arbeiten. Tabelle 3 gibt einen Überblick über die Rahmendaten der in diesem Kapitel behandelten Studien und fasst damit die für die vorliegende Arbeit relevanten Inhalte der recherchierten Studien kurz und knapp zusammen. Die in Tabelle 3 genannten zwölf Studien bilden den Kern der relevanten Erkenntnisse und werden im Folgenden einzeln vorgestellt.

Tabelle 3: Übersicht über Studien zur Routenwahl

| Studie | Jahr der Datenerhebung | Fokus | Untersuchungsraum | Stichprobe | | Einflussfaktoren | Analysemodell |
|---|---|---|---|---|---|---|---|
| | | | | Probanden[3] | Fahrten[4] | | |
| Krizek et al. 2007 | 2005 | Nutzung des „Trail Systems" | Minneapolis (USA) | N = 142 (3.121)<br>Alter: 14-79 Jahre<br>m-w: 57% - 43% | N = 142 (3.121) | Alter, Geschlecht, Wohnort, Befragungsort und -zeit, Wegezweck, Unfallzahlen, Knotenpunkte, Wegelänge auf dem Trail | Ordinary Least Square (OLS) |
| Menghini et al. 2010 | 2004 | Untersuchung der Routenwahl | Zürich (Schweiz) | N ≤ 2.045 (2.435)<br>Alter: k.A.<br>m-w: k.A. | N = 2.498 (73.493) | Fahrtweiten, durchschnittliche Längsneigung, maximale Längsneigung, Radwegeanteil, Anzahl Lichtsignalanlagen (LSA) | Multinomiales Logit |
| Hood et al. 2011 | 2009/2010 | Entwicklung eines Routenwahlmodells | City of San Francisco (USA) | N = 366 (952)<br>Alter: 14-79 Jahre<br>m-w: 79% - 21% | N = 3.034 (7.096) | Fahrtweiten, Wenden (Turns), Anteil Falschfahrten (Richtung), Radverkehrsführungsform, Längsneigung, Geschlecht | Path Size Multinomial Logit |
| Broach et al. 2012, Friedrich et al. 2011 | 2007 | Entwicklung eines Routenwahlmodells | Portland (USA) | N = 154 (164)<br>Alter: 25-64 Jahre (89%)<br>m-w: 79% - 21% | N = 1.449 (1.777) | Fahrtweiten, Wenden (Turns), Längsneigung, LSA, Anzahl Stoppschilder, Radverkehrsführungsform | Path Size Logit |
| Kang & Fricker 2013 | 2006-2008 | Infrastrukturnutzung (on- vs. off-street) | Purdue University, West Lafayette (USA) | N = 178<br>Alter: 18-30 Jahre<br>m-w-: 75% - 24%<br>100% Studenten | N = 931 | Radverkehrsführungsform, Straßenklasse, Länge einzelner Wege-Segmente, Sicherheit, Wegbreite, durchschnittlich tägliche Verkehrsstärke (DTV), LSA, Oberflächenqualität, Fahrtrichtung | Mixed Logit |
| Koh & Wong 2013 | k.A. | Einflussfaktoren der Routenwahl | Singapur (Singapur) | N = 276 (1.146)<br>Alter: 15-49 Jahre (73%)<br>m-w-: 50% - 50% | N = 276 | Verkehrsstärken des MIV, Hindernisse, Unfallrisiko, Szenerie, Längsneigung | Index-Modell, Logit |
| Casello & Usyukov 2014 | 2010/11 | Modellierung der Routenwahl | Waterloo, Ontario (Kanada) | N ≈ 400<br>Alter: k.A.<br>m-w: k.A.<br>erfahrene Radfahrende | N = 724/900 (≈2.000) | Fahrtweite, Verkehrsstärken und Geschwindigkeit des fließenden MIV, Längsneigung, Existenz von Radverkehrsinfrastruktur | Multinomial Logit |
| Khatri et al. 2016 | 2014-2015 | Routenwahl von Bike-Sharing-Nutzer*innen | Downtown Phoenix, Arizona (USA) | N = 1.866<br>Alter: k.A.<br>m-w: k.A.<br>Bike-Sharing-Nutzer*innen | N = 9.101 (20.468) | Fahrtweite, Existenz und Anteil vorhandener Radverkehrsinfrastruktur, Anzahl Abbiegevorgänge, Einbahnstraßennutzung, LSA, DTV MIV | Path Size Logit |
| Ton et al. 2017 | 2015 | Einflussfaktoren der Routenwahl | Amsterdam (Niederlande) | N ≤ 3.045 (≈5.000)<br>Alter: 31-64 Jahre (80%)<br>m-w: k.A.<br>ca. 69% Pendelfahrten | N = 3.045 (12.413) | Fahrtweite, Anzahl Knotenpunkte, Anteil baulich getrennter Radwege, Wegezweck | Multinomial Logit, Path Size Logit |
| Chen et al. 2017 | 2009-2014 | Einfluss der gebauten Umwelt auf die Routenwahl | Seattle (USA) | N = 197<br>Alter: 10-61 Jahre (72%)<br>m-w: k.A.<br>erfahrene Radfahrende | N = 2.922 (3.310) | Alter, Geschlecht, Häufigkeit der Fahrradnutzung, Radverkehrsführungsform, Fahrtweite, Geschwindigkeit des fließenden MIV, Längsneigung, Flächennutzung, Wasser- & Grünflächenanteil, Beleuchtung, Straßenbegleitgrün | Path Size Logit<br>Mixed-Logit Model |
| Zimmermann et al. 2017 | 2012 | Modellierung der Routenwahl | Eugene, Oregon (USA) | N = 103<br>Alter: >26 Jahre (81%)<br>m-w: 74% - 26% | N = 648 | Fahrtweite, Längsneigung, Verkehrsstärken und Geschwindigkeiten des MIV, Freigabe v. Einbahnstraßen, Radverkehrsführungsform, LSA, Stoppschilder | Recursive Logit Model |
| Ghanayim & Bekhor 2018 | 2013-2014 | Routenwahl von Radfahrenden | Tel Aviv (Israel) | N = 221 (8.515)<br>Alter: <40 Jahre (70%)<br>m-w: 73% - 27% | N = 545 (618) | Fahrtweite, Radverkehrsführung, Straßentypen, Flächennutzung, Szenerie | Mixed Multinomial Logit, Mixed Path Size Logit, C-Logit |

[3] N = Anzahl der Proband*innen nach der Datenaufbereitung (In Klammern: Anzahl der Proband*innen vor der Datenaufbereitung); Alter = Alters-Streuung; m-w = Geschlechterverhältnis männlich-weiblich

[4] Fahrtenanzahl nach der Datenaufbereitung (Fahrtenanzahl vor der Datenaufbereitung)

Im Folgenden wird jeweils kurz auf den Fokus der Studien, deren Untersuchungsraum und die verwendeten Methoden eingegangen. Anschließend werden die zentralen Ergebnisse der Studien vorgestellt. Darüber hinaus wird hervorgehoben, welchen Erkenntnisgewinn die Studie im Rahmen der Erforschung der Thematik geleistet hat und inwiefern Lücken in Bezug auf die Thematik der jeweiligen Arbeit bestehen.

Um die Darstellung der Studien übersichtlicher zu gestalten, ist der Beschreibung der einzelnen Studien jeweils eine Informationsbox vorangestellt, die die wesentlichen Inhalte der anschließend beschriebenen Studie kurz und knapp zusammenfassen.

| | | | |
|---|---|---|---|
| Studie: | Krizek et al. 2007 | Fokus: | Untersuchung der Einflussfaktoren der Nutzung des Radverkehrsnetzes in Minneapolis (USA) |
| Ergebnisse: | Die Nutzung von Radverkehrsinfrastruktur ist für Radfahrende derart attraktiv, dass größere Umwege für deren Nutzung in Kauf genommen werden. | | |
| Beitrag: | Es handelt sich um eine der ersten Arbeiten, die RP-Daten für die Analyse nutzt. | | |
| Kritik: | Kleine Stichprobe und nur wenige Einflussfaktoren berücksichtigt. | | |

Die Arbeit von Krizek, El-Geneidy und Thompson 2007 war eine der ersten Studien, die auf Basis von RP-Daten und mittels multivariater Analyse das Verkehrsverhalten von Radfahrenden untersuchte. In ihrer Studie untersuchten die Autoren im Raum Minneapolis (USA) die Wirkung der Eigenschaften des urbanen Radverkehrsnetzes auf seine Nutzung durch Radfahrende. Dazu wurden im Jahr 2005 an 13 Punkten im Radwegenetz mehr als 3.000 Proband*innen zu ihren Fahrten befragt und Daten zu deren Präferenzen, Quellen, Zielen und Wegezwecken erhoben. Für die statistische Schätzung des genutzten OLS-Modells (Ordinary Least Square) konnten insgesamt Daten von 142 Proband*innen genutzt werden. Die gefahrenen Routen wurden mit den kürzesten Wegen verglichen. Außerdem flossen personenspezifische Attribute (z.B. Alter und Geschlecht) als auch fahrtenspezifische Attribute (z.B. Wegezweck und Wegelängen) in die Analyse ein.

Die zentralen Ergebnisse der Studie können wie folgt zusammengefasst werden: Die von den Radfahrenden gewählten Routen entsprechen in der Regel nicht der kürzesten Route, sondern sind um den Faktor 1,2 länger. Zudem erscheint die Nutzung geeigneter Radinfrastruktur so attraktiv, dass die Mehrzahl der Radfahrer*innen Umwege sowie das Durchfahren zusätzlicher Knotenpunkte in Kauf nimmt, um die Radverkehrsinfrastruktur nutzen zu können.

Die Studie ist die erste dokumentierte Arbeit, in der Zusammenhängen zwischen der Routenwahl von Radfahrenden und unterschiedlichen Einflussfaktoren basierend auf RP-Daten analysiert wurden. Grenzen der Studie bestehen darin, dass eine sehr kleine Stichprobe von Fahrten (n = 142) für die statistische Schätzung der Zusammenhänge genutzt wurde. Zudem fehlen in der Analyse weitere wichtige Einflussvariablen (z.B. Radverkehrsführungsform, Oberfläche oder Steigung) und weitere mögliche Routenalternativen jenseits der kürzesten Wege.

| | | | |
|---|---|---|---|
| Studie: | Menghini et al. 2010 | Fokus: | Untersuchung der Einflussfaktoren der Routenwahl in Zürich (Schweiz) |
| Ergebnisse: | Radfahrende bevorzugen kürzere und weniger steile Routen, auf denen Radverkehrsinfrastruktur, aber möglichst wenige LSA-geregelte Knotenpunkten vorhanden sind. | | |
| Beitrag: | Nachweis der Nutzbarkeit von GPS-basierten RP-Daten für die Analyse der Routenwahl | | |
| Kritik: | Es konnten nur wenige Einflussfaktoren berücksichtigt werden. | | |

Die Arbeit von Menghini, et al. 2010 ist eine der ersten Studien, in der die Routenwahl von Radfahrer*innen anhand von GPS-basierten RP-Daten analysiert wurde. Ziel der Studie war die Untersuchung von Einflussfaktoren und deren Wirkung auf die Routenwahl von Radfahrenden im Raum Zürich (Schweiz). Dazu konnten die Autoren auf Daten einer großen Erhebung aus dem Jahr 2004 zurückgreifen, innerhalb derer insgesamt mehr als 73.000 Wege von etwa 2.435 Proband*innen per GPS aufgezeichnet wurden. Für die Untersuchung wurden letztlich rund 2.500 GPS-Tracks (Radfahrten) genutzt. In der statistischen Schätzung des Multinomialen Logit-Modells wurden die Einflussfaktoren Fahrtweite, Längsneigung, Radwegeanteil und die Anzahl der auf den Routen liegenden Lichtsignalanlagen (LSA) berücksichtigt.

Die Studie konnte aufzeigen, dass die von den Proband*innen gewählten Routen im Vergleich zu den möglichen Alternativrouten kürzer und weniger steil waren. Es wurde zudem deutlich, dass Radfahrende Routen mit Radinfrastruktur und weniger Knotenpunkten mit Lichtsignalanlagen präferieren.

Die Studie von Menghini, et al. 2010 erbrachte als erste Studie überhaupt den Nachweis, dass eine Analyse der Routenwahl von Radfahrer*innen mittels GPS-Daten möglich ist. Sie verdeutlichte zudem, dass Radfahrende sensitiv auf bestimmte Einflussfaktoren reagieren und ihre Route entsprechend wählen. Grenzen der Studie bestehen darin, dass das für die Studie genutzt Netzmodell bzw. seine Eingangsdaten nicht genügend detaillierte Informationen liefern konnten, um weitere Einflussfaktoren (z.B. Art der Radverkehrsführung oder ruhender Verkehr) in die Analyse einfließen zu lassen. Die Einflussfaktoren konnten also nur rudimentär abgebildet und integriert werden (siehe Menghini, et al. 2010). Aufgrund fehlender Information zur Stichprobe lässt sich die Güte und Repräsentativität der Stichprobe nicht einschätzen.

| | | | |
|---|---|---|---|
| Studie: | Hood et al. 2011 | Fokus: | Entwicklung eines Routenwahlmodells für die Stadt San Francisco (USA) |
| Ergebnisse: | Radfahrer*innen präferieren separat geführte Radwege und bevorzugen kürzere Routen. Sie meiden hingegen Steigungen und viele Abbiegevorgänge. | | |
| Beitrag: | Erste Studie für den US-Raum. Nachweis zur Nutzbarkeit von GPS-Routendaten, die mittels Smartphone-App erfasst wurden. Untersuchung weiterer Einflussfaktoren. | | |

| | |
|---|---|
| Kritik: | Stark männlich dominierte Stichprobe gut vernetzter (erfahrener) Radfahrender. |

Hood, Sall und Charlton 2011 untersuchten als erste die Routenwahl von Radfahrenden im US-amerikanischen Raum. Sie integrierten zusätzliche Variablen in ihre Analysen, die in vorigen Studien (siehe z.B. Menghini, et al. 2010) nicht berücksichtigt wurden. Grundlage der Analysen sind Daten aus einer fünfmonatigen Datenerhebung in San Francisco (USA) in den Jahren 2009/2010. Während der Erhebung wurden über die Smartphone-App *CycleTracks* zum einen die gefahrenen Wege via GPS-Tracking aufgezeichnet. Zum anderen wurden weitere personenspezifische Attribute (z.B. Alter und Geschlecht) der Proband*innen erfasst. Nach der Datenbereinigung flossen schließlich 3.034 Routen von 366 Radfahrer*innen in die statistische Analyse ein. Für die Analyse wurden die Charakteristika der Routen wie bspw. Routenlängen, Radverkehrsführungsformen oder Längsneigungen je Route berechnet.

Die Arbeit zeigt auf, dass separat geführte Radwege gegenüber anderen Führungsformen bevorzugt und Steigungen gemieden werden. Diese Präferenzen treffen vor allem auf weniger erfahrene Radfahrer*innen zu. Zudem weisen Hood, Sall und Charlton 2011 nach, dass eine zunehmende Routenlänge sowie eine zunehmende Anzahl an Kehren bzw. Abbiegevorgängen (turns) einen negativen Einfluss auf die Auswahlwahrscheinlichkeit einer Route ausübt. Die Autoren fanden jedoch keinen Effekt des Verkehrsaufkommens sowie der Geschwindigkeiten des motorisierten Verkehrs auf die Routenwahlwahrscheinlichkeit.

Die Studie konnte zum ersten Mal für den US-Raum aufzeigen, welche Faktoren die Routenwahl beeinflussen. Die Autoren schätzen die Ergebnisse ihrer Studie vor allem für die Anwendung in Verkehrsumlegungsmodelle als hilfreich ein, da mit Hilfe ihrer Ergebnisse Maßnahmen zur Verbesserungen der Radverkehrsinfrastruktur abgeschätzt werden können. Die Studienergebnisse müssen jedoch vor allem hinsichtlich der Stichprobe kritisch hinterfragt werden, weil die Teilnahme an der Studie auf Proband*innen mit Smartphone beschränkt war. Darüber hinaus wurde der Aufruf zur Studienteilnahme bzw. zum Tracking über Fahrradverbände und -vereine verbreitet, sodass wohl hauptsächlich erfahrene und gut vernetzte Radfahrer*innen an der Erhebung teilnahmen. Zusätzlich wies die Stichprobe einen hohen Anteil männlicher Nutzer auf (79 %).

| | | | |
|---|---|---|---|
| Studie: | Broach et al. 2012 / Friedrich et al. 2011 | Fokus: | Einfluss der Infrastrukturausstattung auf das Radverkehrsaufkommen und die Routenwahl in Portland (USA) |
| Ergebnisse: | Radfahrende bevorzugen separat geführte Radwege oder das Fahren im Nebennetz. Streckenabschnitte mit hohen Verkehrsstärken des motorisierten Verkehrs oder Steigungen werden ebenso gemieden wie LSA-geregelte Kontenpunkte. | | |
| Beitrag: | Bestätigung und Erweiterung der Erkenntnisse voriger Studien. | | |

| | |
|---|---|
| Kritik: | Kleine und männlich dominierte Stichprobe. |

Die Studien von Broach, Dill und Gliebe 2012 und Friedrich, et al. 2011 basieren auf den gleichen Arbeiten und untersuchten den Einfluss der Infrastrukturausstattung auf das Radverkehrsaufkommen und die Routenwahl für die Metropolregion Portland in Oregon (USA). Im Rahmen der Arbeit wurden im Jahr 2007 über mehrere Monate GPS-Routendaten von 164 Radfahrenden erhoben. Diese wurden mit soziodemographischen Daten, die in einer zusätzlichen Befragung erhoben wurden, verknüpft. Darüber hinaus wurden Sekundärdaten aus einem bestehenden Netzmodell der Stadt herangezogen, sodass eine Vielzahl von Einflussfaktoren (z.B. DTV des MIV, Längsneigungen oder Radverkehrsführungsformen) in die Analyse der Routenwahl einbezogen werden konnten. Für die statistische Schätzung wurde ein Path Size Logit genutzt.

Die zentralen Ergebnisse der Studien sind, dass Radfahrende bei ihrer Routenwahl separat geführte Radwege bevorzugen oder das Fahren auf Routen im Nebennetz präferieren. Die Studien zeigen ebenso auf, das Radfahrende Straßen mit hohen Verkehrsstärken des motorisierten Verkehrs (MV) meiden. Dies trifft sowohl auf unerfahrene als auch auf erfahrene Radfahrende zu und ist nach Broach, Dill und Gliebe 2012 neben der Fahrtweite einer der wichtigsten Einflussfaktoren der Routenwahl. Darüber hinaus bevorzugten Radfahrende Routen, auf denen eine gute Radverkehrsinfrastruktur vorhanden ist (im Fall von Portland sind dies vor allem sog. *bike boulevards*) und nur vergleichsweise geringe Steigungen zu überwinden sind. Radfahrende meiden zudem Routen mit Knotenpunkten, die durch eine LSA geregelt sind oder an denen Vorfahrt zu beachten ist. Ausnahmen konnten beim Linksabbiegen oder beim Queren von Straßen mit hohen Verkehrsstärken des MV beobachtet werden.

Die Arbeiten von Broach, Dill und Gliebe 2012 und Friedrich, et al. 2011 bestätigen die Ergebnisse vorheriger Studien und ergänzen sie teilweise. In Ergänzung zu den bisher beschriebenen Arbeiten ist festzuhalten, dass keine deutlichen Unterschiede bei der Routenwahl unterschiedlicher Geschlechter oder Altersgruppen gefunden wurden. Dies ist möglicherweise auf die Stichprobengröße und die Stichprobenauswahl (80 % der Studienteilnehmenden waren männlich) zurückzuführen.

| | | | |
|---|---|---|---|
| Studie: | Kang & Fricker 2013 | Fokus: | Analyse der Präferenzen bei der Infrastrukturnutzung (Mischverkehr vs. separate Führung) |
| Ergebnisse: | Präferenz der Radfahrer*innen zum Fahren im Mischverkehr. Entlang von Strecken mit hohem DTV des MIV werden separate Führungsformen bevorzugt. Geringe Breiten der Führung üben eine negativen Einfluss auf die Routenwahl aus. | | |

| | |
|---|---|
| Beitrag: | Integration zahlreicher Einflussfaktoren in die Analysen. Nutzung der Modellergebnisse zur Berechnung von Szenarien. |
| Kritik: | Sehr homogene Probandengruppe (100 % Student*innen) und kleine Stichprobe (n=178). |

Kang und Fricker 2013 analysierten in ihrer Studie die Nutzung unterschiedlicher Radverkehrsführungsformen. Sie untersuchten die Präferenzen hinsichtlich der Nutzung von Infrastruktur, bei der der Radverkehr gemeinsam mit dem Kfz-Verkehr geführt wurde (on-street) oder auf separaten Wegen (off-street). Die Untersuchung basieren auf Befragungen, die auf dem Campus der *Purdue University* in Indiana (USA) durchgeführt wurden. Im Rahmen der Befragung wurden Student*innen bei ihrer Ankunft auf dem Campus u.a. nach ihren Routen und ihrer Wegenutzung gefragt. Vom Jahr 2006 bis 2008 wurden auf diese Weise 178 Radfahrende zu insgesamt 931 Fahrten befragt. Auf Basis der Befragungen und weiterer Sekundärdaten führten Kang und Fricker 2013 eine statistische Analyse (Mixed Logit Model) durch, um den Einfluss personenspezifischer Merkmale (z.B. Alter, Geschlecht), umfeldbezogener Variablen (z.B. Tageszeit, Windgeschwindigkeit, Temperatur) und routenspezifischer Variablen (z.B. Straßenkategorie, Fahrstreifenanzahl, Längsneigung, ruhender Verkehr, DTV des MIV, Oberflächenbeschaffenheit) auf die Routenwahl zu analysieren.

Ergebnis ihrer Analyse ist, dass Radfahrende das Fahren auf der Straße (on-street) allgemein präferieren. Die Autoren vermuten, dass in diesem Punkt ein Zusammenhang zur Oberflächenbeschaffenheit besteht. Beim Fahren entlang von Hauptverkehrsstraßen und Straßen mit hohem DTV des Kfz-Verkehrs tendieren Radfahrer*innen jedoch zur Nutzung separat geführter Radwege (off-street). Diese werden in dem Fall gegenüber jeglicher anderer Führungsformen auf der Fahrbahn (z.B. Radfahrstreifen) bevorzugt. Eine geringe Breite der Führung wirkt sich allgemein negativ auf die Routenwahl aus. Die Autoren schließen aus ihrer Analyse, dass bei der Nutzung der Radverkehrsinfrastruktur (off-street versus on-street) ein Zusammenhang zu dem Sicherheitsempfinden besteht.

Die Studie stellte zum Zeitpunkt der Veröffentlichung eine der umfangreichsten Studien dar, weil zahlreiche Einflussfaktoren in die Analysen einflossen. Kang und Fricker 2013 nutzten ihre Modellergebnisse zur Berechnung unterschiedlicher Szenarien, mit denen Sie die Nutzung von Radverkehrsinfrastruktur nach deren potentieller Umgestaltung aufzeigten. Sie betonen in ihrer Studie jedoch, dass ihr Modell die Nutzung von on-street-Segmenten in gewissem Grad überschätzt. Darüber hinaus lässt der Fokus der Arbeit (on-street vs. off-street) nur wenig differenzierte Aussagen zur Nutzung unterschiedlicher Radverkehrsführungsformen zu. Die Ergebnisse lassen sich aufgrund der homogenen Stichprobenzusammensetzung (100 % Student*innen; 75 % davon männlich) und der kleinen Stichprobengröße (n=178) nur schwer generalisieren.

| | | | |
|---|---|---|---|
| Studie: | Koh und Wong 2013 | Fokus: | Einfluss infrastruktureller Faktoren auf die Routenwahl. |
| Ergebnisse: | Komfort ist ein wichtiger Einflussfaktor. Radfahrende bevorzugen Strecken entlang von Hauptverkehrsstraßen mit geringen Längsneigungen, weiteren Radfahrer*innen und einer ästhetischen schön empfundenen Szenerie. | | |
| Beitrag: | Erste Studie zur Untersuchung der Routenwahl im asiatischen Raum. Verifizierung bisheriger Erkenntnisse zum Thema. | | |
| Kritik: | Verhältnismäßig kleine Stichprobe. Untersuchung weniger Einflussfaktoren. | | |

Koh und Wong 2013 betrachten in ihrer Studie sowohl den Rad- als auch den Fußverkehr und versuchen die Einflüsse von infrastrukturellen Faktoren auf die Routenwahl beider Verkehrsmodi abzuschätzen. Die Eingangsdaten der Analyse stammen aus einer Erhebung, die an fünf unterschiedlichen Bahnstationen in Singapur durchgeführt wurde. Insgesamt wurden 1.146 Interviews geführt, in denen die Proband*innen nach ihren Wegen und den jeweils genutzten Routen befragt wurden. Sie wurden zudem aufgefordert, vorgegebene Einflussfaktoren in Bezug auf ihr persönliches Routenwahlverhalten nach Relevanz zu beurteilen bzw. zu gewichten. Für den Radverkehr wurden nach der Datenaufbereitung 276 Datensätze für die anschließende logistische Regressionsanalyse genutzt. Im Rahmen der Befragung wurden zwar unterschiedliche Einflussfaktoren abgefragt (z.B. Anzahl von Knotenpunkten entlang einer Route, Komfortempfinden, Längsneigung, Sicherheit usw.). Es wurden jedoch nicht alle Variablen in der Modellschätzung berücksichtigt.

Aus der Analyse geht hervor, dass Radfahrende komfortable Routen in der Nähe großer Straßen bevorzugen, auf denen weitere Radfahrende präsent sind. Zudem präferieren die Radfahrenden Routen mit einer als schön empfundenen Szenerie und nur geringen Längsneigungen. Komfort wird von den Autoren als ein zentraler Einflussfaktor der Routenwahl identifiziert.

Die Studie von Koh und Wong 2013 leistet einen Beitrag zum Verständnis der Routenwahl in Singapur und stellt die erste Studie zur Thematik in diesem Untersuchungsgebiet dar. Der Stichprobenumfang (276 Fahrten von ebenso vielen Proband*innen) fällt im Vergleich zu anderen Studien jedoch verhältnismäßig gering aus. Darüber hinaus wurden vergleichsweise wenig Einflussfaktoren in die Analyse integriert.

| | | | |
|---|---|---|---|
| Studie: | Casello & Usyukov 2014 | Fokus: | Untersuchung der Routenwahl in Waterloo (USA) |
| Ergebnisse: | Negativer Einfluss zunehmender Fahrtweiten sowie hoher Längsneigungen und Geschwindigkeiten des MIV. Die Existenz von Radverkehrsinfrastruktur übt einen positiven Einfluss auf die Routenwahl aus. | | |

| | |
|---|---|
| Beitrag: | Erste Studie zur Routenwahl im kanadischen Raum. |
| Kritik: | Geringe Modell-Güte. Sehr homogene Proband*innengruppe (sehr erfahrene Radfahrer*innen). |

Casello und Usyukov 2014 untersuchten in ihrer Studie die Einflussfaktoren der Routenwahl von Radfahrenden in Waterloo, Ontario (Kanada). Sie nutzten dazu einen GPS-Datensatz, der von rund 400 Radfahrenden im Jahr 2010 und 2011 erhoben wurde. In dem genannten Zeitraum zeichneten die Proband*innen für jeweils 2 Wochen ihre Routen mittels GPS-Loggern auf. Auf diese Weise wurden GPS-Daten zu mehr als 2.000 Fahrten aufgezeichnet. Nach der Datenbereinigung konnten schließlich rund 905 Fahrten für die Analyse genutzt werden. Darüber hinaus fanden weitere Sekundärdaten zur Abbildung der unterschiedlichen Einflussfaktoren (z.B. Informationen zur Radverkehrsinfrastruktur, Fahrtweiten, Verkehrsstärken und Geschwindigkeiten des fließenden MIV, Längsneigung) Eingang in die Analyse. Für die statistische Schätzung wurden zwei multinomiale Logit-Modelle geschätzt, die sich nur aufgrund der einbezogenen Einflussfaktoren unterschieden. Die Modelle wurden mit 724 zufällig gewählten Tracks der Stichprobe geschätzt (80 %). Die restlichen 181 Tracks (20 %) wurden für die Modellvalidierung genutzt.

Das zentrale Resultat der Studie ist, dass sich zunehmende Fahrtweiten sowie höhere Längsneigungen und Geschwindigkeiten des fließenden MIV entlang einer Route negativ auf deren Wahlwahrscheinlichkeit auswirken. Ein Vorhandensein von Radverkehrsinfrastruktur wirkt sich hingegen positiv aus. Die Verkehrsstärke des MIV entlang der Routen hat hingegen keinen nennenswerten Einfluss auf die Routenwahlwahrscheinlichkeit. Die Autoren weisen in ihrer Studie ausdrücklich darauf hin, dass die beiden Modelle nur eine geringe bis mittelhohe Güte besitzen (nur 46 % bzw. 65 % korrekte Prognose).

Die Studie von Casello und Usyukov 2014 ist die erste Studie für eine kanadische Stadt, in der mittels RP-Daten das Routenwahlverhalten von Radfahrenden untersucht wurde. Die Studienergebnisse sind aufgrund fehlender Informationen schwer einzuschätzen. So fehlen bspw. Angaben zur Alter- oder Geschlechterverteilung der Proband*innen. Zudem beinhaltet die Stichprobe nur erfahrene Radfahrende. Dies könnte bspw. den geringen Einfluss der Distanz auf die Routenwahl erklären, der in anderen Studien deutlich stärker wirkt.

| | | | |
|---|---|---|---|
| Studie: | Khatri et al. 2016 | Fokus: | Routenwahl von Bike-Sharing-Nutzer*innen in Phoenix |

| | |
|---|---|
| Ergebnisse: | Kürzere Fahrtweiten, die Existenz von Radverkehrsinfrastruktur und LSA-geregelte Knotenpunkte üben einen positiven Einfluss auf die Routenwahl aus. Ein hoher DTV des Kfz-Verkehr verringert die Wahlwahrscheinlichkeit. Kein Einfluss des Unfallgeschehens. |
| Beitrag: | Erkenntnisse zur Routenwahl von Bike-Sharing-Nutzer*innen. |
| Kritik: | Nutzer*innengruppe stellt nur ein Spektrum der Radfahrenden dar. Fehlende Informationen zur Stichprobe erschweren die Interpretation und den Vergleich mit anderen Studien. |

Khatri, et al. 2016 untersuchten in ihrer Arbeit die Routenwahl von Bike-Sharing-Nutzer*innen für das Innerstadtgebiet von Phoenix, Arizona (USA). Sie konnten dazu auf Daten von *Grid Bikeshare* aus dem Innenstadtgebiet von Phoenix aus dem Jahr 2014/15 zurückgreifen. Der Datensatz enthielt insgesamt 20.468 Fahrten von 1.866 Nutzer*innen, die von November 2014 bis Mai 2015 mit Rädern des Bike-Sharing-Anbieters unterwegs waren. Datenbereinigung und Datenverarbeitungsprozesse reduzierten die Stichprobe auf 9.101 nutzbare Fahrten. Zur Integration relevanter Einflussfaktoren wurden weitere Sekundärdaten herangezogen. Dazu wurden aus dem Netzmodell der Stadt Phoenix Informationen zur Radverkehrsinfrastruktur und zum DTV des Kfz-Verkehrs genutzt. Die Autoren griffen darüber hinaus auf Informationen zum Unfallgeschehen, den Geschwindigkeiten des fließenden Kfz-Verkehrs sowie der Regelung von Knotenpunkten zurück. Für die Analyse wurden zwei Logit-Modelle (Path Size Logit) geschätzt. Die Routenwahl wurde zudem für unterschiedliche Gruppen von Nutzer*innen (gelegentliche Nutzung vs. regelmäßige Nutzung) analysiert.

Die Ergebnisse von Khatri, et al. 2016 zeigen, dass Radfahrende kürzere Routen bei der Routenwahl bevorzugen. Regelmäßige Nutzer*innen reagieren dabei sensibler auf längere Distanzen als Gelegenheitsnutzer*innen. Diese wählen eher Routen mit höheren Geschwindigkeiten des MIV, während regelmäßige Nutzer*innen eher Routen mit geringeren Geschwindigkeiten des fließenden Verkehrs bevorzugen. Ein hoher DTV des MIV entlang einer Routen wirkt sich bei beiden Gruppen negativ auf die Wahlwahrscheinlichkeit einer Route aus. Sicherheitsaspekte, die in der Analyse über eine Unfallquote (Unfälle pro Meile) abgebildet wurden, zeigten keinen signifikanten Einfluss auf die Routenwahl beider Gruppen. Beide Gruppen wiesen generell eine hohe Präferenz für die Nutzung von Routen mit Radverkehrsinfrastruktur auf. Eine steigende Anzahl von LSA entlang der Route wirkte sich positiv auf die Routenwahl aus. Die Autoren interpretieren dies als ein Indiz für die Erhöhung der Sicherheit durch die Nutzung von LSA beim Queren von Straßen. Eine steigende Anzahl von Abbiegevorgängen wirkte sich hingegen negativ auf die Auswahlwahrscheinlichkeit einer Route aus.

Die Studienergebnisse bestätigen einen Großteil der Erkenntnisse aus anderen Arbeiten. Neu sind vor allem die Erkenntnisse hinsichtlich der Präferenzen von Radfahrenden, die Bike-Sharing-Angebote nutzen. Die Stichprobe bildet jedoch nur einen Teil der Grund-

gesamtheit aller Radfahrenden in Phoenix ab. Die Ergebnisse lassen sich somit nur bedingt auf alle Radfahrenden der Stadt übertragen. Darüber hinaus erschwert dies den Vergleich mit den Ergebnissen bereits vorgestellter Studien. Es fehlen zudem Informationen zu den Radfahrer*innen (bspw. Alter oder Geschlecht), was die Einordnung der Ergebnisse erschwert.

| | | | |
|---|---|---|---|
| Studie: | Ton et al. 2017 | Fokus: | Routenwahl in der Innenstadt von Amsterdam |
| Ergebnisse: | Negativer Einfluss von zunehmender Fahrtweite und Anzahl von Knotenpunkten. Kein Einfluss von separat geführten Radwegen auf die Routenwahl. | | |
| Beitrag: | Entwicklung und Nutzung eines neuen Verfahrens zur Erzeugung von Routenalternativen. | | |
| Kritik: | Geringe Güte des Analysemodells und eingeschränkte Übertragbarkeit der Ergebnisse durch die Ausprägung des Radverkehrs in Amsterdam. | | |

Ton, et al. 2017 untersuchten in ihrer Studie die Routenwahl von Radfahrenden in der Innenstadt von Amsterdam (Niederlande). Sie nutzten dafür GPS-Daten, die während der niederländischen Fahrradzählwoche (*Fietstelweek*) vom 14. bis 20. September 2015 in den Niederlanden erhoben wurden. Im Rahmen der *Fietstelweek* zeichneten landesweit rund 38.000 Radfahrer*innen ihre Wege mittels Smartphone-App auf. Darüber hinaus wurden die sozidemographischen Eigenschaften der Radfahrenden mit einer Begleiterhebung erfasst. Im Innenstadtgebiet von Amsterdam wurden insgesamt rund 12.400 Fahrten von ca. 5.000 Radfahrer*innen erhoben. Nach der Datenaufbereitung flossen 3.045 Fahrten in die Analysen ein. Für die Modellschätzung mit logistischer Regression (Path Size Logit und Multinomial Logit) wurden eine Vielzahl von Variablen identifiziert. Aufgrund der Datenverfügbarkeit konnten jedoch nur Fahrtweiten, Wegezwecke, der Anteil der baulich getrennten Radwege sowie die Anzahl der Knotenpunkte entlang einer Route in die Modellschätzung einbezogen werden.

Die Ergebnisse der Studie entsprechen in etwa den Ergebnissen vorheriger Studien. Die Autor*innen belegen in ihrer Studie, dass die Distanz einer Route und die Anzahl der auf ihr zu passierenden Knotenpunkte einen signifikant negativen Einfluss auf die Routenwahl haben. Die Distanz hat vor allem während der Morgenstunden einen stark negativen Einfluss auf die Routenwahl. Ein Ergebnis der Arbeit steht jedoch den Resultaten anderer Studien fundamental entgegen: Die Analysen von Ton, et al. 2017 zeigen auf, dass ein Vorhandensein baulich getrennter Radwege keinen wesentlichen Einfluss auf die Routenwahl hat. Sie interpretieren den fehlenden Einfluss mit der Annahme, dass das Radfahren in der Stadt bereits stark etabliert ist.

Die Ergebnisse der Arbeit bestätigen jedoch größtenteils die Erkenntnisse bisheriger Studien – mit Ausnahme des oben geschilderten Zusammenhangs. Eine zentrale Erkenntnis aus der Arbeit von Ton, et al. 2017 bezieht sich vor allem auf die genutzte Methode zur

Erzeugung der Routenalternativen. In den bisherigen Studien wurden stets Routenalternativen mittels Routensuchverfahren erzeugt. Die Autor*innen nutzen für die Erzeugung von Routenalternativen jedoch einen anderen Ansatz, den sie als *empirical approach* bezeichnen. Sie nutzen dafür nur die tatsächlich genutzten Routenalternativen auf den Quelle-Ziel-Relationen, anstatt Routenalternativen über Routensuchalgorithmen zu erzeugen. Darüber hinaus gelangen sie zu der Erkenntnis, dass das verwendete Logit-Modell (Path Size Logit) eine höhere Modell-Güte als das üblicherweise genutzte multinomiale Logit-Modell besitzt. Die Autor*innen führen dies auf den sog. *path size factor* zurück, der eine Überschätzung des Nutzens von überlappenden Alternativen unterbindet (siehe IIA-Problem in Kapitel 2.2.4). Grenzen der Arbeit bestehen in der geringen Modell-Güte. Nach Einschätzung der Autor*innen lassen sich die Ergebnisse aufgrund der speziellen Ausprägung des Radverkehrs in Amsterdam zudem nur schlecht auf andere Gebiete übertragen.

| Studie: | Chen et al. 2017 | Fokus: | Einfluss der Stadtstruktur auf die Routenwahl in Seattle |
|---|---|---|---|
| Ergebnisse: | Kürzere Distanzen, geringe Längsneigung und niedrigere Geschwindigkeiten des fließenden Kfz-Verkehrs beeinflussen die Routenwahl ebenso positiv wie das Vorhandensein von Straßenbegleitgrün, Straßenbeleuchtung und Grün- und Wasserflächen. | | |
| Beitrag: | Untersuchung besonders vieler Einflussfaktoren. Valide Ergebnisse durch große Stichprobe (fast 3.000 Fahrten). | | |
| Kritik: | Sehr homogene Stichprobenzusammensetzung (vor allem erfahrene Radfahrer*innen) erschwert Übertragbarkeit und Generalisierbarkeit der Ergebnisse. | | |

Chen, Shen und Childress 2017 untersuchten in ihrer Arbeit den Einfluss der Stadtstruktur und des Verkehrsnetzes auf die Präferenzen bei der Routenwahl von Radfahrenden in Seattle (USA). Dazu nutzten sie GPS-Routendaten, die in den Jahren 2009 bis 2014 erhoben wurden. Zur Datenerhebung wurde die Smartphone-App *Cycletracks* verwendet. Insgesamt wurden in dem genannten Zeitraum mehr als 3.300 Radfahrten via App aufgezeichnet. Nach der Datenbereinigung standen noch 2.922 Tracks von 197 Radfahrenden für die Analysen zur Verfügung. Die erhobenen Routendaten wurden mit weiteren Sekundärdaten angereichert. Die Autor*innen berücksichtigten insgesamt vier Klassen von Einflussvariablen in ihrer Analyse: personenspezifische Variablen (z.B. Alter, Geschlecht, Häufigkeit der Radnutzung), Komfort (z.B. Distanz, Verfügbarkeit von Radabstellanlagen), Sicherheit (z.B. Geschwindigkeit des MIV, Beleuchtung, Radwegetyp) und sog. freizeitbezogene Einflüsse (z.B. Straßenbäume, Szenerie).

Als zentrale Einflussfaktoren identifizieren Chen, Shen und Childress 2017 die Distanz einer Route, die Geschwindigkeiten des fließenden MIV entlang der genutzten Streckenabschnitte, die Längsneigung, den Anteil von Radverkehrsinfrastruktur entlang einer Route sowie das Vorhandensein von Straßenraumbeleuchtung. Die Studienergebnisse zeigen, dass Radfahrende Routen mit kurzen Distanzen, geringen Längsneigungen und

niedrigeren Geschwindigkeiten des fließenden Kfz-Verkehrs bevorzugen. Zudem wirken sich das Vorhandensein von Straßenbegleitgrün, Straßenbeleuchtung, die Nähe einer Route zu Grün- und Wasserflächen sowie Gebieten mit hoher Durchmischung der Landnutzung positiv auf die Auswahl einer Route aus.

Die Arbeit von Chen, Shen und Childress 2017 ist besonders hervorzuheben, weil es den Autor*innen gelungen ist, viele potentielle Einflussfaktoren der Routenwahl in die Analyse einzubeziehen. Darüber hinaus ist die genutzte Stichprobe der RP-Daten mit fast 3.000 Fahrten im Vergleich zu anderen Studien sehr groß. Dem steht jedoch die Zusammensetzung der Stichprobe gegenüber, die vor allem Fahrten erfahrener Radfahrer*innen enthält. In Anbetracht dieser Tatsache sind die Studienergebnisse schwer generalisier- bzw. übertragbar.

| | | | |
|---|---|---|---|
| Studie: | Zimmermann et al. 2017 | Fokus: | Einflussfaktoren der Routenwahl in Eugene |
| Ergebnisse: | Positiver Einfluss von Radverkehrsinfrastruktur entlang einer Route. Zunehmende Fahrtweiten, hohe Längsneigungen und Verkehrsstärken üben einen negativen Einfluss auf die Routenwahl aus. | | |
| Beitrag: | Neuer methodischer Ansatz verkürzt die Berechnungszeit. | | |
| Kritik: | Kleiner Stichprobenumfang. Männliche Radfahrende dominieren die Stichprobe. | | |

Zimmermann, Mai und Frejinger 2017 untersuchten in ihrer Studie die Einflussfaktoren der Routenwahl für das Gebiet von Eugene, Oregon (USA). Für die Arbeit konnten die Autor*innen auf Daten der *Central Lane Metropolitan Planning Organization* zurückgreifen, die im Rahmen einer Studie im Jahr 2012 Daten zum Radverkehrsverhalten erhoben hatte. Die Routendaten wurden mit der Smartphone-App *CycleLane* erhoben. Neben den Routendaten wurden zudem Informationen zu den App-Nutzenden selbst (z.B. soziodemographische Daten) sowie bzgl. der Fahrten (z.B. Wegezweck einer Fahrt) abgefragt. Nach der Datenaufbereitung konnten 648 Fahrten von 103 Nutzer*innen in die Analyse einfließen. Es wurden zudem zahlreiche Sekundärdaten aufbereitet (u.a. Distanz, Längsneigung, Verkehrsstärken und Geschwindigkeiten des fließenden Kfz-Verkehrs, Führungsform des Radverkehrs, Anzahl der LSA entlang der Route, Vorfahrtsregelung), die eine Integration zahlreicher Einflussfaktoren in die Analyse gestattete. Für die Analyse nutzten die Autor*innen ein sog. *link-based recursive logit model*.

Die zentralen Ergebnisse der Studie lassen sich wie folgt zusammenfassen: Die Existenz von Radverkehrsinfrastruktur entlang einer Route zeigt einen positiven Einfluss und erhöht deren Auswahlwahrscheinlichkeit. Im Gegensatz dazu haben große Fahrtweiten, hohe Längsneigungen und Verkehrsstärken (vor allem des Schwerverkehrs) sowie eine zunehmende Anzahl von Abbiegevorgängen entlang einer Route einen signifikant negativen Einfluss auf deren Auswahlwahrscheinlichkeit.

Die Studienergebnisse bestätigen im Wesentlichen die Resultate bisheriger Studien. Darüber hinaus leistet die Studie einen methodischen Beitrag, indem sie aufzeigt, dass mit dem gewählten Ansatz (*link-based recursive logit model*) die Erzeugung eines Choice Sets (Generieren von Routenalternativen), die üblicherweise durchgeführt wird, nicht notwendig ist. Nach Zimmermann, Mai und Frejinger 2017 liegt der Vorteil der Methode vor allem in der Einsparung von Berechnungszeit. Den methodischen Stärken der Arbeit steht die geringe Datenbasis gegenüber. Die genutzte Stichprobe enthält rund 648 Fahrten von etwas mehr als 100 Proband*innen. Dieser Eingangsdatensatz ist im Vergleich zu anderen Studien sehr klein. Des Weiteren beinhaltet die Stichprobe einen sehr hohen Anteil männlicher Radfahrender (ca. 74 %).

| | | | |
|---|---|---|---|
| Studie: | Ghanayim & Bekhor 2018 | Fokus: | Einflussfaktoren der Routenwahl in Tel Aviv |
| Ergebnisse: | Präferenz zur Nutzung von kürzeren Routen und Radverkehrsinfrastruktur. Radfahrer*innen meiden Routen entlang großer Straßen mit vielen Knotenpunkten. Wohngebiete, Parks und Wasserflächen üben einen positiven Einfluss auf die Routenwahl aus. | | |
| Beitrag: | Gebietsspezifische Erkenntnisse und Vergleich unterschiedlicher Analysemodelle. | | |
| Kritik: | Geringer Stichprobenumfang und homogene Stichprobe. | | |

In der Studie von Ghanayim und Bekhor 2018 untersuchten die Autoren die Routenwahl von Radfahrenden in Tel Aviv (Israel). Sie nutzen dafür GPS-Routendaten, die im Rahmen einer Haushaltbefragung in Tel Aviv von Dezember 2013 bis Juni 2014 erhoben wurden. Im Rahmen der Haushaltsbefragung wurden die insgesamt 8.515 Probanden mit GPS-Loggern ausgestattet und 24 Stunden lang alle Wege aufgezeichnet. Insgesamt wurden bei der Erhebung 618 Radfahrten erfasst. Nach der Datenaufbereitung konnten 545 Radfahrten von 221 Proband*innen für die Analysen genutzt werden. Die Autoren untersuchten den Einfluss diverser Faktoren (z.B. Fahrtweite, Vorhandensein von Radverkehrsinfrastruktur, Straßentypen, Flächennutzung etc.) auf die Routenwahl. Für die statistische Schätzung wurden drei unterschiedliche logistische Regressionsmodelle genutzt (Multinomial Logit, C-Logit, Path Size Logit).

Die Ergebnisse der Arbeit spiegeln die Ergebnisse voriger Studien größtenteils wider. Sie lassen sich wie folgt zusammenfassen: Radfahrende in Tel Aviv wählen eher kürzere Routen, zeigen jedoch die Bereitschaft längere Routen zu nutzen, wenn auf diesen Strecken Radverkehrsinfrastruktur vorhanden ist. Sie meiden bei ihrer Routenwahl Strecken entlang von großen Straßen und Routen mit vielen Knotenpunkten. Strecken durch Wohngebiete werden ebenso präferiert wie Strecken durch Parks oder entlang der Küste. Es konnte kein Einfluss der Längsneigung nachgewiesen werden. Ein weiteres Ergebnis der Studie ist, dass die verschiedenen Modelle eine unterschiedliche Modell-Güte aufweisen. Das Path Size Logit und das C-Logit zeigten eine höhere Modell-Güte als das Multinomial

Logit, weil sie mögliche Überlappungen von Routenalternativen in der Modellschätzung berücksichtigen können.

Die Studie ist die erste Arbeit für eine Stadt im Raum Israel und leistet vor allem bzgl. des Modellvergleichs einen wichtigen Forschungsbeitrag. Ebenso wie in vielen anderen Studien ist der Stichprobenumfang (545 Fahrten) jedoch sehr gering. Es ist nicht auszuschließen, dass sich die geringe Fahrtenanzahl auf die Repräsentativität der Ergebnisse auswirkt. Darüber hinaus ist die Stichprobe kritisch zu hinterfragen. Die Proband*innen waren überdurchschnittlich jung (70 % jünger als 40 Jahre) und überwiegend männlich (73 %). Methodisch muss zudem hinterfragt werden, ob das gewählte Vorgehen bei der Erzeugung der Routenalternativen sinnvoll ist (für jede beobachtete Fahrt wurden bis zu 20 Routenalternativen erzeugt). Andere Studien zeigen auf, dass bereits relativ wenige Alternativen für ein robustes Choice Set ausreichend sind.

## 3.3 Zusammenfassung der Recherche

Die Beschreibung existierender Studien hat verdeutlicht, dass eine Vielzahl von Studien zum Thema der vorliegenden Arbeit existieren. Auch wenn diese auf Daten unterschiedlicher Untersuchungsräume basieren, Erhebungszeiträume sich teilweise stark unterscheiden und der Fokus der Studien teils variiert, lassen sich dennoch Tendenzen zur Wirkung der Einflussfaktoren auf die Routenwahl von Radfahrenden erkennen. Dazu gehören bspw. der negative Einfluss großer Fahrtweiten und hoher Längsneigungen oder der positive Einfluss vorhandener Radverkehrsinfrastruktur und geringerer Geschwindigkeiten des fließenden Kfz-Verkehrs.

Aus der Betrachtung der Studien geht jedoch auch hervor, dass sich deren Ergebnisse nicht auf den deutschen Raum übertragen lassen. Gründe dafür lassen sich vor allem in den unterschiedlichen Eigenschaften der Untersuchungsräume selbst sowie in der Datenbasis (Qualität und Quantität der Stichprobe) finden.

Die Untersuchungsgebiete der Studien stellen eine maßgebliche Einschränkung für die Übertragbarkeit der Forschungsergebnisse auf den deutschen Raum dar. Die meisten Analysen wurden für Städte in den USA durchgeführt. Weitere Untersuchungsgebiete lagen in der Schweiz, Kanada, den Niederlanden, Israel oder Singapur. Die Tatsache, dass die Studien in unterschiedlichen Städten durchgeführt wurden, ist im Sinne der Übertragbarkeit der Studienergebnisse als problematisch anzusehen, weil sich diese Städte teils erheblich unterscheiden können. So unterscheiden sich die Untersuchungsräume bspw. hinsichtlich der Stadtstruktur (z.B. Bebauungsstruktur, Straßenmuster und -netz, Topographie) erheblich. Ebenso kann der politische oder kulturelle Hintergrund einen maßgeblichen Einfluss auf die Fahrradnutzung und die Routenwahl ausüben.

Ein weiterer Grund dafür, die Ergebnisse vieler bisheriger Studien zu hinterfragen ist die Datengrundlage, auf deren Basis die Untersuchungen durchgeführt wurden. Die Stichproben der Studien unterscheiden sich nicht nur stark. Sie weisen teilweise auch große Lücken auf. Diese beziehen sich vor allem auf die geringen Stichprobenumfänge. Sowohl eine zu geringe Anzahl an Proband*innen (z.B. in der Studie von Zimmermann, Mai und Frejinger 2017) als auch eine zu geringe Anzahl aufgezeichneter Fahrten (z.B. in der Arbeit von Koh und Wong 2013) beeinflussen die Aussagekraft der Studienergebnisse.

Eine Problematik mit hoher Relevanz stellt die Zusammensetzung der Stichproben dar. Viele Studien nutzen zwar Daten, die eine ausreichend große Menge an Proband*innen und Fahrten beinhalten (siehe bspw. Hood, Sall und Charlton 2011 oder Khatri, et al. 2016). Die Stichproben sind jedoch in nahezu allen Studien sehr homogen. In der bereits angesprochenen Studie von Khatri, et al. 2016 nutzten bspw. alle Proband*innen das Bike-Sharing-System und es erscheint fraglich, ob die Nutzer*innen von Fahrradverleihsystemen die durchschnittlichen Fahrradfahrer*innen repräsentieren. Die Stichprobe von Casello und Usyukov 2014 beinhaltet wiederum hauptsächlich Daten von erfahrenen Radfahrenden und deckt somit nicht das gesamte Spektrum aller Radfahrenden ab. Andere Studien nutzten Daten aus Stichproben, in denen die Geschlechterverteilung der Radfahrenden durch einen überproportional großen Anteil männlicher Probanden verzerrt war (siehe bspw. Hood, Sall und Charlton 2011). Die Stichprobe, die Kang und Fricker 2013 für ihre Analyse nutzten, ist durch eine sehr homogene Gruppe von Nutzer*innen bestimmt (100 % Student*innen). In vielen Stichproben anderer Studien ist vor allem die Altersverteilung der Radfahrenden nicht repräsentativ (siehe bspw. Broach, Dill und Gliebe 2012 oder Kang und Fricker 2013).

Die obigen Beschreibungen verdeutlichen, dass die Ergebnisse der Studien nur bedingt übertragbar sind. Dies ist vor allem auf die Eigenschaften der Untersuchungsräume und die Stichprobeneigenschaften der genutzten Daten zurückzuführen.

# 4. Methodisches Vorgehen

Für die Durchführung der vorliegenden Arbeit wurde eine Vielzahl unterschiedlicher Methoden genutzt. In den folgenden Abschnitten des Kapitels sollen diese Methoden detailliert vorgestellt werden. Abbildung 10 stellt das methodische Vorgehen überblicksartig dar.

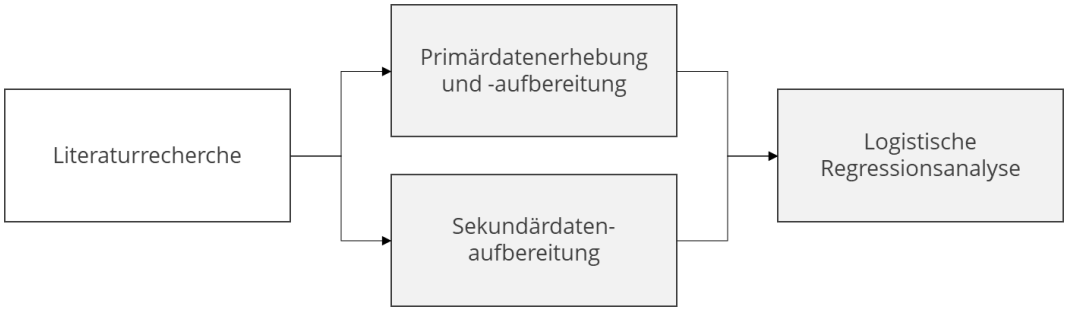


Abbildung 10: Überblick über das methodische Vorgehen

Da die genutzten Methoden auf unterschiedliche Weise miteinander verknüpft sind und ihr Zusammenspiel im Rahmen der vorliegenden Arbeit teils sehr komplex ist, wird im abschließenden Abschnitt (siehe Kapitel 4.4) noch einmal ein Gesamtüberblick über den Ablauf und die Verknüpfung der einzelnen Schritte gegeben.

## 4.1 Untersuchungsraum – Dresden

Um ein besseres Verständnis für die Notwendigkeit der Methoden zur Datenerhebung und -aufbereitung (sowohl der Primärdaten, als auch der Sekundärdaten) zu erhalten und im späteren Verlauf der Arbeit die Ergebnisse besser einordnen zu können, wird in den folgenden Abschnitten der Untersuchungsraum vorgestellt. Der allgemeinen Einordnung des Raumes folgt die Darstellung der verkehrlichen Situation im Untersuchungsgebiet.

### 4.1.1 Allgemeine geographische Einordnung

Faktoren wie Relief, (Mikro-) Klimate, Flächennutzung und die Struktur einer Stadt können bei der Routenwahl von entscheidender Relevanz sein und eine Steigerung/Verminderung der Attraktivität von Routen bewirken (siehe Kapitel 3). Für eine bessere Einordnung der späteren Ergebnisse der Arbeit werden sie daher an dieser Stelle kurz für das Untersuchungsgebiet benannt.

Dresden ist die Landeshauptstadt des Bundeslandes Sachsen und liegt an der Elbe im südöstlichen Teil des Bundeslandes. Die Topographie der Stadt ist maßgeblich durch die Elbe und das Elbtal geprägt. Sie liegt in der sog. Elbtalweitung, die sich maßgeblich auf

das Relief der Stadt auswirkt. Während der Nullpunkt des Elbepegels bei ca. 102,7 m liegt, steigt das Relief zu den Hängen beidseitig der Elbe steil an – höchster Punkt ist der 383 m hohe Triebenberg (TSP-Dresden 2020). Die Topographie wirkt sich zudem auf das Stadtklima aus, sodass das feuchtgemäßigte Klima mittlerer Breiten im Elbtal milder ausfällt (LH-Dresden-a 2019).

Dresden ist mit seinen 328,48 km² flächenmäßig die viertgrößte Stadt in Deutschland. Das Stadtgebiet dehnt sich in Nord-Süd-Richtung auf 22,6 km und in Ost-West-Richtung auf 27,1 km aus (TSP-Dresden 2020). Die Stadtflächen lassen sich in die übergeordneten Kategorien Vegetations- und Wasserflächen (64 % der Stadtfläche), Siedlungsflächen (34 % der Stadtfläche) und Verkehrsflächen (2 % der Stadtfläche) unterteilen (LH-Dresden-b 2020).

Die Stadt verfügt über eine polyzentrische Stadtstruktur. Linkselbisch (südwestlich der Elbe) liegt die Altstadt mit dem historischen Zentrum. Rechtselbisch (nordöstlich der Elbe) befindet sich die Neustadt Dresdens. Entsprechend der Stadtgeschichte unterscheiden sich die einzelnen Stadtgebiete deutlich bzgl. Bebauungsdichte, Gebäudesubstanz, Verkehrsflächen, Grünflächenanteilen usw. Das stetige Bevölkerungswachstum in den letzten Dekaden hat dazu geführt, dass heute mehr als 563.000 Einwohner (2019) in Dresden leben (LH-Dresden-c 2020).

### 4.1.2 Verkehrssituation

Die Nutzung des Fahrrads als alltägliches Verkehrsmittel hat in Dresden seit der Wiedervereinigung stetig zugenommen, sodass in den letzten Jahren starke Zugewinne beim Radverkehr im Modal Split verzeichnet wurden (Abbildung 11). Im Jahr 2018 war das Fahrrad für rund 18 % der Wege das Verkehrsmittel der Wahl (LH-Dresden-d 2020).

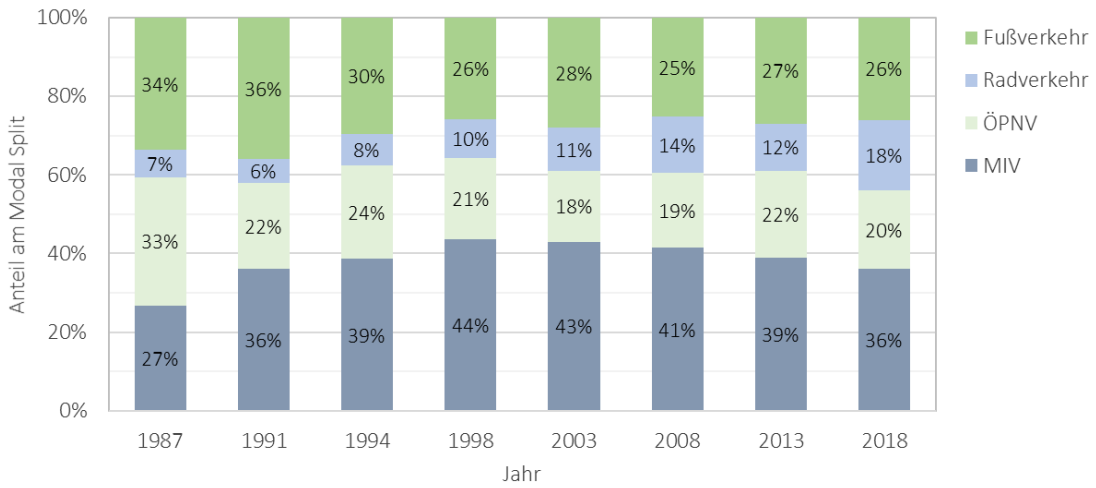


Abbildung 11: Entwicklung des Modal Split für Dresden
(Eigene Darstellung nach LH-Dresden-d 2020)

Die Radverkehrsanteile sind in den zentralen Bereichen der Stadt besonders groß. Der höchste Anteil des Radverkehrs am Modal Split ist bspw. mit ca. 33% in der Dresdner Neustadt zu finden. Davon abgesehen ist jedoch im gesamten Dresdner Stadtgebiet ein starkes Wachstum des Radverkehrs zu verzeichnen (ebd.).

Den Dresdener Haushalten stehen im Durchschnitt 1,6 Fahrräder zur Verfügung. Am häufigsten wird das Fahrrad von der Gruppe der Jugendlichen bzw. jungen Erwachsenen im Alter von 15 bis unter 25 Jahren genutzt (28 % der Wege). Erwachsene im Alter von 25 Jahren bis unter 45 Jahren nutzen das Fahrrad im Durchschnitt am zweithäufigsten (23 % der Wege), gefolgt von Kindern und Jugendlichen im Alter bis 15 Jahren (20 % der Wege). Mit steigendem Alter sinkt die Fahrradnutzung und damit der Radverkehrsanteil im Modal Split deutlich (siehe Abbildung 12).

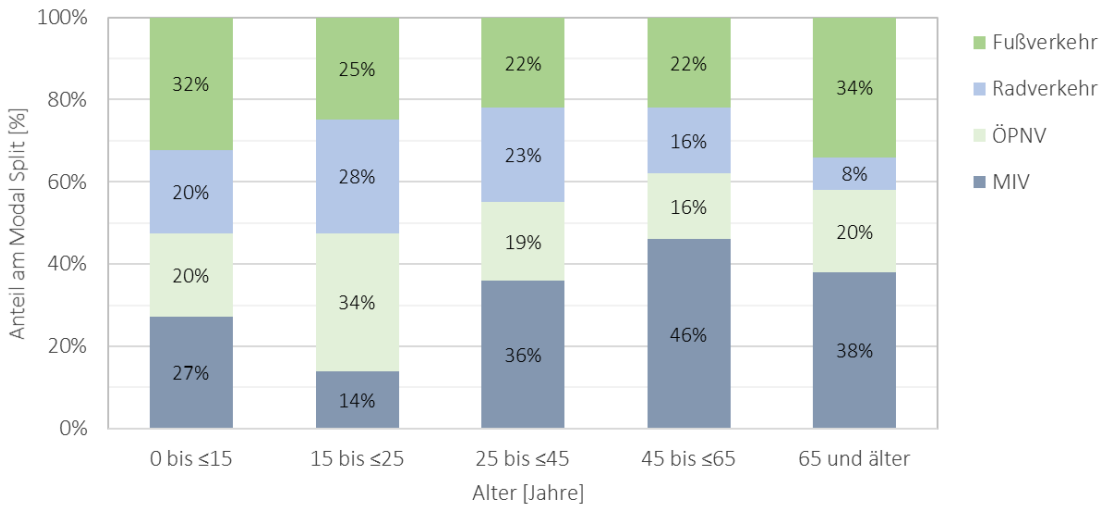


Abbildung 12: Modal Split in Dresden 2018 nach Altersgruppen
(Eigene Darstellung nach LH-Dresden-d 2020)

Insgesamt stieg die Anzahl der Fahrten, die mit dem Fahrrad durchgeführt wurden, in den Jahren 2013 bis 2018 um ca. 70 % auf durchschnittlich 362.000 Fahrten pro Tag (2018). Im gleichen Zeitraum stieg ebenfalls der Anteil der Bevölkerung, die täglich das Fahrrad nutzt (Anstieg von 16 % auf 20 % in 2018). Die Dresdener Radfahrenden legten im Jahr 2018 im Durchschnitt rund 1,23 Millionen Kilometer pro Tag zurück (LH-Dresden-d 2020).

Die Nutzung des Fahrrads hängt in Dresden jedoch stark von der zu überwindenden Distanz ab. So wird das Fahrrad in der Stadt am häufigsten für kurze Wege mit einer Fahrtweite zwischen 1 km und 3 km genutzt (rund 27 % aller Fahrten). Mit zunehmender Wegelänge sinkt der Anteil der Fahrradnutzung auf rund 20 % (3 km bis ≤ 5 km). Bei längeren Fahrten wird zunehmend auf andere Verkehrsmittel zurückgegriffen und der Anteil der Fahrradnutzung fällt deutlich ab (siehe Abbildung 13).

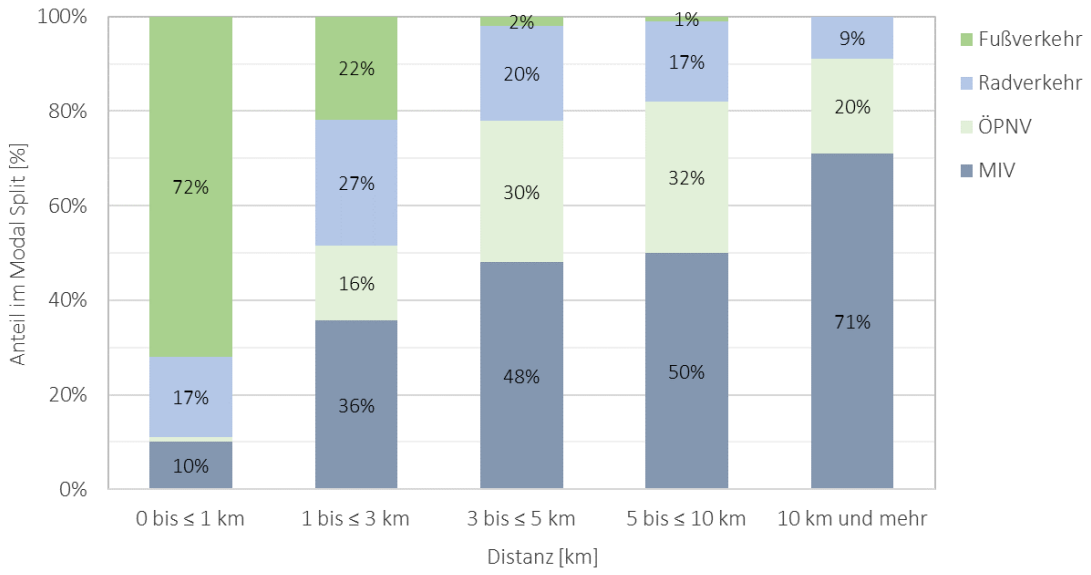


Abbildung 13: Modal Split in Dresden 2018 nach Entfernungsklassen
(Eigene Darstellung nach LH-Dresden-d 2020)

Neben der zu überwindenden Distanz ist der Wegezweck ein wesentlicher Einflussfaktor der Fahrradnutzung. Der Anteil der Fahrradnutzung ist bei Wegen der Zwecke „Kita/Schule/Ausbildung“ am höchsten (rund 27 %). Es folgen Wege zum Arbeitsplatz und zurück (Heimweg) sowie Wege mit anderen Zwecken oder Fahrten zu Freizeitzwecken (siehe Abbildung 14).

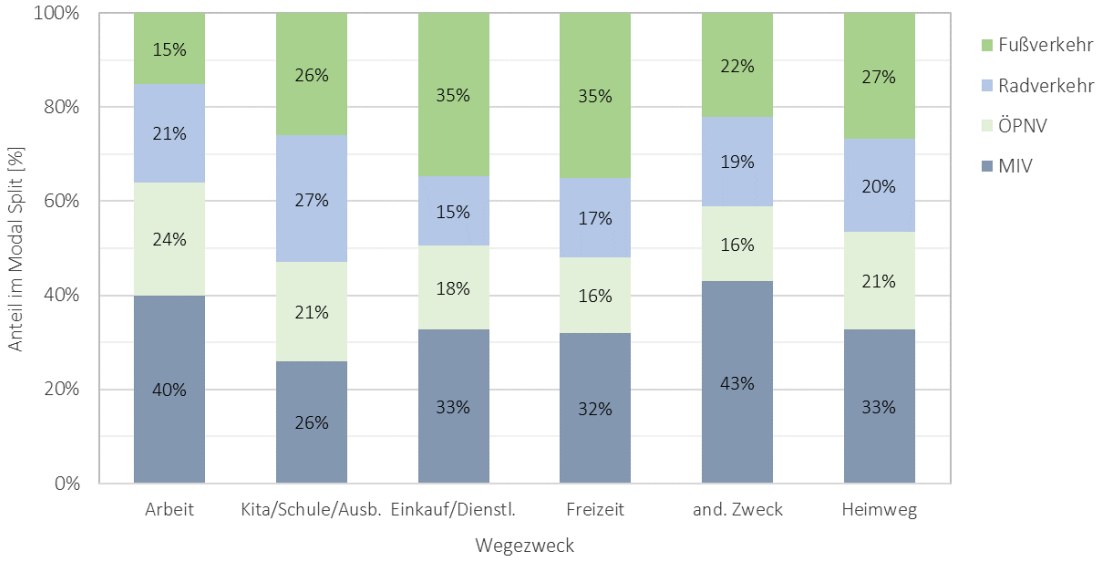


Abbildung 14: Modal Split in Dresden 2018 nach Wegezwecken
(Eigene Darstellung nach LH-Dresden-d 2020)

Nur rund 6 % der Dresdner legen ihre Alltagswege monomodal mit dem Fahrrad zurück. Der überwiegende Teil der Bevölkerung wechselt im Alltag regelmäßig das Verkehrsmittel. Das bedeutet, dass ein Großteil der Radfahrenden auch andere Verkehrsmittel nutzt und zwischen Fahrrad und bspw. ÖPNV wechselt (LH-Dresden-d 2020). Dieser Fakt

wird sich auch in der notwendigen Primärdatenaufbereitung wiederspiegeln (siehe Kapitel 4.2.1.2).

Neben Wegelängen existieren noch weitere Faktoren, wie bspw. Jahreszeiten und Wetter oder bestimmte Lebensstile und Einstellungen, die die Nutzung des Fahrrads als Verkehrsmittel beeinflussen. Sie sollen an dieser Stelle jedoch nicht weiter betrachtet werden. Weiterführende Informationen zum Radverkehr in Dresden können bspw. aus LH-Dresden-d 2020 entnommen werden. Darüber hinaus wird im Rahmen der Ergebnisbeschreibung in Kapitel 5 noch detailliert auf die Charakteristika des Radverkehrs in Dresden (z.B. Wegelängen, Alters- und Geschlechterverteilung der Radfahrenden usw.) eingegangen.

Die in den obigen Abschnitten beschriebenen Ergebnisse basieren auf den Ergebnisdaten aus der Erhebung SrV 2018 aus dem Jahr 2018 (LH-Dresden-d 2020). Sollte die Nutzung des Fahrrads in der jüngeren Vergangenheit weiter gewachsen sein, so ist davon auszugehen, dass die Radverkehrsanteile im Modal Split aktuell (Stand 2021) sogar über den Werten aus dem Erhebungszeitraum von SrV 2018 liegen. Als ein Indiz dafür können bspw. die Ergebnisse aus Querschnittszählungen (z.B. Dauerzählstellen) herangezogen werden. Sie zeigten schon im Jahr 2019 einen Anstieg der Fahrten an den gemessenen Querschnitten im Dresdner Stadtgebiet gegenüber 2018 (LH-Dresden-e 2019).

Bei der Betrachtung der räumlichen Ausprägung des Radverkehrs ist vor allem eine Konzentration der Radverkehrsnachfrage im Hauptverkehrsnetz und auf den ausgewiesenen Radfernwegen (z.B. Elberadweg) zu beobachten (LH-Dresden-f 2017). Die Daten der Dauerzählstellen sowie Informationen aus temporären Kurzzeitzählungen können zwar kein vollständiges Bild der Verteilung des Radverkehrs im Stadtgebiet aufzeigen. Ergebnisse des Forschungsprojekts „Mit Smartphones generierte Verhaltensdaten im Radverkehr“ vermitteln jedoch einen guten Eindruck über die Verteilung des Radverkehrs im Stadtgebiet. Abbildung 15 zeigt eine im Rahmen des Projekts veröffentlichte Verkehrsmengenkarte für Dresden, die auf GPS-Daten des App-Anbieters Strava basieren (Lißner, Francke und Becker 2017).

Auch wenn die Datengrundlage nicht alle Radfahrenden im Untersuchungsgebiet repräsentiert, so genügt sie an dieser Stelle, um einen ersten Eindruck über die räumliche Verteilung des Radverkehrs in Dresden zu erhalten (ebd.). Die Abbildung stützt die Aussage, dass Radfahrende im Untersuchungsgebiet vor allem das Hauptverkehrsnetz und die ausgewiesenen Radfernwege (v.a. den Elberadweg) nutzen.

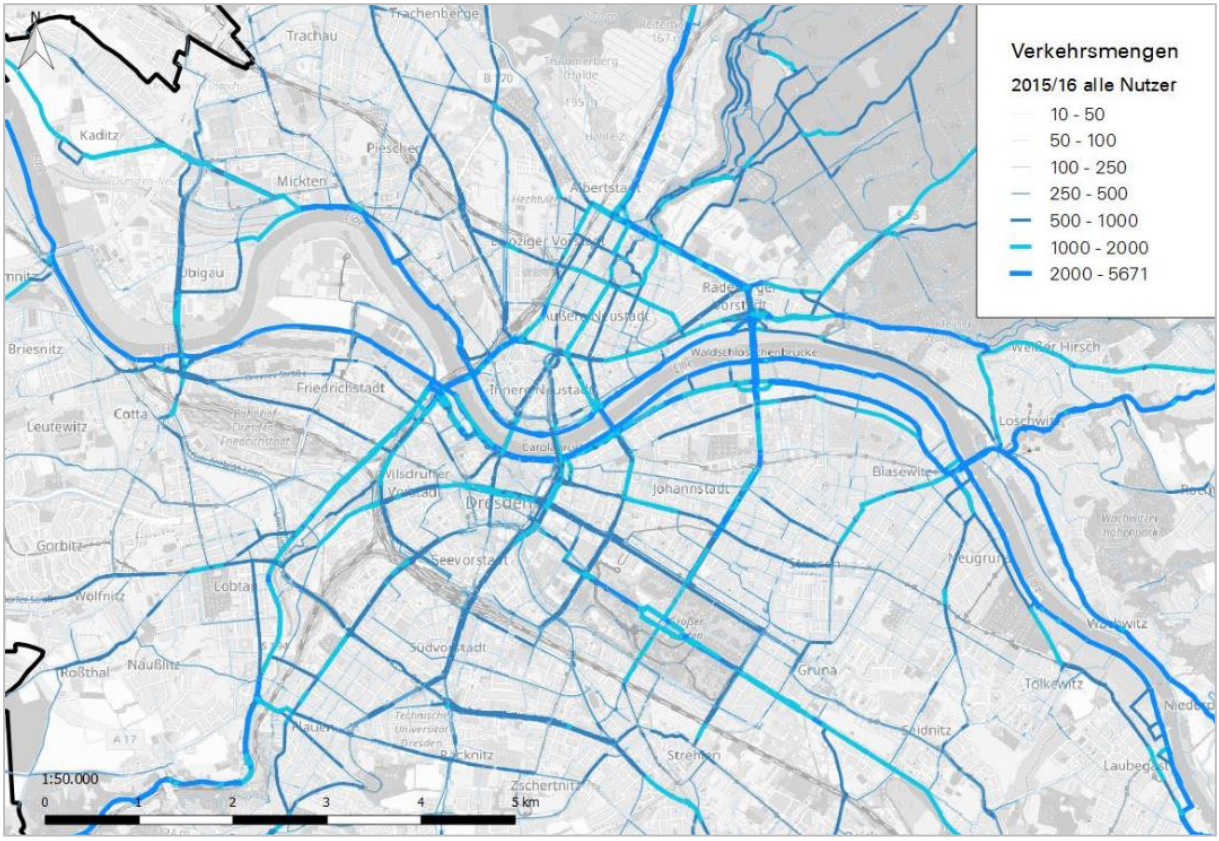


Abbildung 15: Radverkehrsmengen in Dresden im Jahr 2015/16 (Quelle: Lißner, Francke und Becker 2017)

Zur Befriedigung der Radverkehrsnachfrage unterhält die Stadt Dresden ein umfangreiches Radwegenetz. Die Strecken im Radverkehrsnetz weisen unterschiedlichste Führungsformen auf. Die Führung im Mischverkehr ist, bezogen auf die Länge des Gesamtstreckennetzes, eine der am häufigsten vorkommenden Führungsformen im städtischen Verkehrsnetz. Es existieren jedoch auch zahlreiche Radfahrstreifen, Schutzstreifen sowie baulich getrennte Radwege. Detaillierte Informationen zum Radwegenetz und den unterschiedlichen Führungsformen können dem Anhang 1 entnommen werden.

Nach LH-Dresden-f 2017 wurde das Radwegenetz in den letzten Jahren erheblich erweitert. Die Gesamtlänge belief sich im Jahr 2016 auf rund 400 km (ebd.). Im Jahr 2020 betrug die Länge des Radwegenetzes ca. 420 km Radwegenetz (LH-Dresden-j 2020).

Im Dresdner Radverkehrskonzept, das zur Förderung des alltäglichen und touristischen Radverkehrs im Jahr 2017 verabschiedet wurde, wurde eine Zustandsanalyse des Radverkehrsangebotsnetzes durchgeführt (LH-Dresden-f 2017). Die zentralen Ergebnisse dieser Analyse lassen sich wie folgt zusammenfassen:

- An vielen Hauptverkehrsstraßen sind Radverkehrsanlagen vorhanden.
- Die Radverkehrsanlagen weisen teils eine sehr unterschiedliche Qualität auf.
- In der Vergangenheit sanierte oder umgebaute Straßen mit Radverkehrsanlagen besitzen teilweise noch eine unbefriedigende Qualität.

- Planerische Grundlagen für die Weiterentwicklung der Radverkehrsanlagen wurden nur punktuell umgesetzt.
- Es existiert kein einheitlicher Standard für Fahrradabstellanlagen und Fahrradabstellplätze an Haltestellen.
- Es existieren großzügige Regelungen für die Fahrradmitnahme in öffentlichen Verkehrsmitteln.
- Ein Netz mit Wegweisung ist vorhanden – jedoch ohne einheitliche Qualität.

Es lässt sich zusammenfassen, dass das Radverkehrsangebot der Stadt Dresden in den letzten Jahren ausgebaut wurde. Zeitgleich konnte ein erheblicher Anstieg der Radverkehrsnachfrage beobachtet werden.

## 4.2 Daten

Um die Analysen der vorliegenden Arbeit zu realisieren, ist eine umfangreiche Datenarbeit notwendig. Für die Umsetzung der Arbeit wurden zahlreiche Daten recherchiert, erhoben und aufbereitet. In den folgenden Abschnitten werden die genutzten Daten und Methoden detailliert beschrieben.

### 4.2.1 Primärdatenerhebung und -aufbereitung

Daten zum beobachteten Routenwahlverhalten der Radfahrenden stellen die Basis für die Analysen der vorliegenden Arbeit dar. Datenquelle sind die während der Aktion STADTRADELN von den Teilnehmer*innen via Smartphone-App erhobenen und übermittelten GPS-Daten (nähere Erläuterungen dazu im nachfolgenden Kapitel 4.2.1.1).

Die Aufbereitung dieser Daten ist von besonderer Relevanz. Aufgrund der großen Datenmenge lassen sich die Routendaten nicht manuell plausibilisieren, sodass ein automatisiertes Verfahren für die Primärdatenaufbereitung entwickelt und genutzt wurde (siehe Kapitel 4.2.1.2). Abbildung 16 verdeutlicht die Abläufe der Datenverarbeitung von der Erhebung bis zu den aufbereiteten Fahrtendaten, die für die Analyse der Routenwahl genutzt wurden. Die Methoden der Datenerhebung sowie die Aufbereitung der Primärdaten werden in den folgenden Kapiteln detailliert dargestellt.

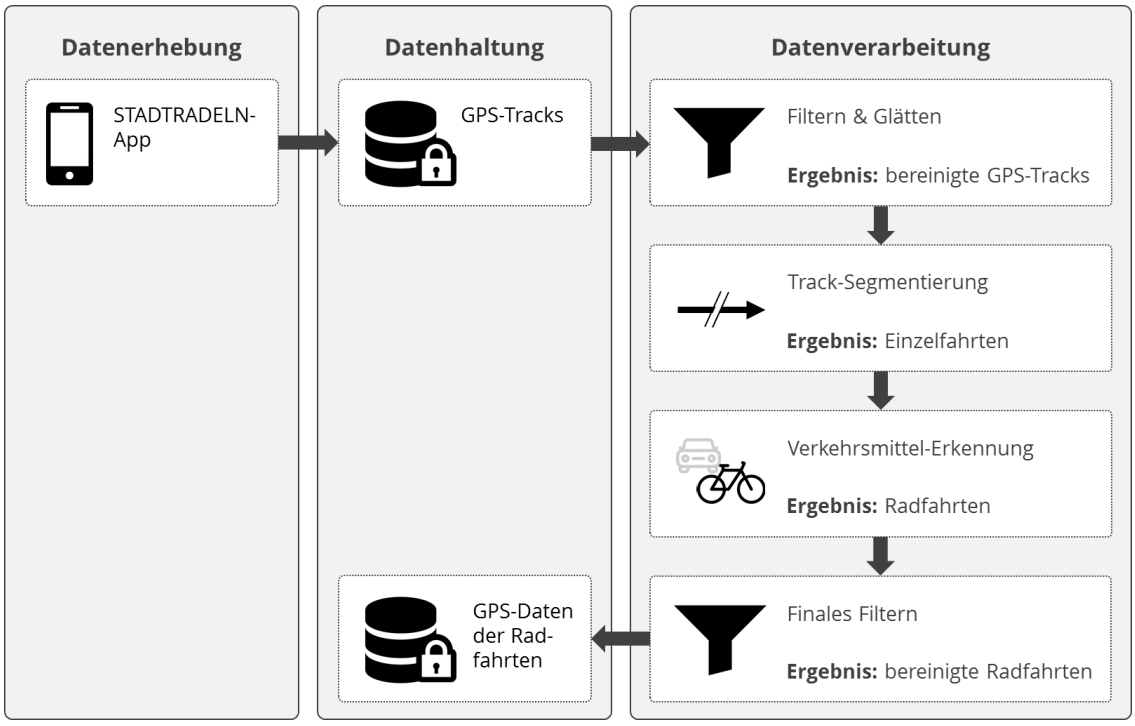


Abbildung 16: Überblick über Primärdatenerhebung und -aufbereitung

#### 4.2.1.1 Datenerhebung

Um die Routenwahl im Radverkehr im Rahmen der vorliegenden Arbeit analysieren zu können, sind verlässliche Daten zu den gewählten Routen von Radfahrenden notwendig. Daher wurde auf Routendaten aus einer Datenerhebung zurückgegriffen, die im Rahmen des vom Bundesministerium für Verkehr und digitale Infrastruktur (BMVI) geförderten Forschungsprojekt „MOVEBIS – Nutzung Auswertung von Crowdsourced-Daten zur Verbesserung der kommunalen Fahrradinfrastruktur“ realisiert wurde.

Die Datenerhebung erfolgte im Rahmen der Aktion STADTRADELN (Stadtradeln 2020). Das STADTRADELN ist eine Kampagne, die seit dem Jahr 2008 vom Klima-Bündnis durchgeführt wird. Das Klima-Bündnis ist ein Netzwerk bestehend aus rund 1.700 Städten, Gemeinden und Landkreisen, die gemeinsam den kommunalen Klimaschutz vorantreiben möchten. Ein wesentliches Ziel ist öffentlichkeitswirksame Arbeit und Unterstützung aktiver Mobilität als eine Maßnahme im Kampf gegen den Klimawandel (Klima-Bündnis 2020).

Im Rahmen der Aktion STADTRADELN, die jedes Jahr im Zeitraum vom 1. Mai bis 30. September stattfindet, wird in den teilnehmenden Kommunen für einen dreiwöchigen Zeitraum zur Nutzung des Fahrrads auf Alltagswegen aufgerufen. Die Aktion STADTRADELN findet in einem Zeitraum statt, der nach den Empfehlungen für Verkehrserhebungen (EVE) für die Datenerhebung empfohlen wird. Darin werden „jahresmittlere“ Monate (März bis Oktober) für die Erhebungen im Radverkehr empfohlen (FGSV 2012).

Das STADTRADELN fand in Dresden im Jahr 2019 vom 24. Juni bis zum 14. Juli statt. Die dreiwöchige Datenerhebung wurde damit in zwei sog. Normalwochen (letzte Juni- und erste Juliwoche) durchgeführt. Nach FGSV 2012 sind dies Wochen, die nicht durch besondere Ereignisse geprägt sind und die daher für Erhebungen des üblichen Verkehrsverhaltens gewählt werden sollten. Bei der letzten Woche im Erhebungszeitraum (zweite Juliwoche) handelte es sich um eine Ferienwoche.

Die Motivation der teilnehmenden Radfahrer*innen ist es, in den drei Wochen möglichst viele Wege mit dem Fahrrad zurückzulegen und so, im Vergleich zur Nutzung des Pkw, Wege möglichst CO2-frei zurückzulegen. Zur Aufzeichnung der mit dem Fahrrad zurückgelegten Wege wurde vom Klima-Bündnis eine App für Smartphones der Betriebssysteme Android und iOS bereitgestellt. Die am STADTRADELN teilnehmenden Bürger*innen konnten sich die STADTRADELN-App in den entsprechenden Stores (App-Store von Apple bzw. Play-Store von Google) herunterladen und damit während des Kampagnen-Zeittraums ihre Fahrten aufzeichnen.

Abbildung *17* zeigt die Nutzeroberfläche der STADTRADELN-App. Die Aufzeichnung kann zu Beginn einer Fahrt durch die Radfahrenden über den grünen Play-Button (siehe mittlere Abbildung) gestartet und am Ende der Fahrt über den gleichen Button beendet werden. Nach Aufzeichnungsende wird die gefahrene Route angezeigt (siehe Abbildung rechts), die geradelten Kilometer dokumentiert und der GPS-Track hochgeladen.

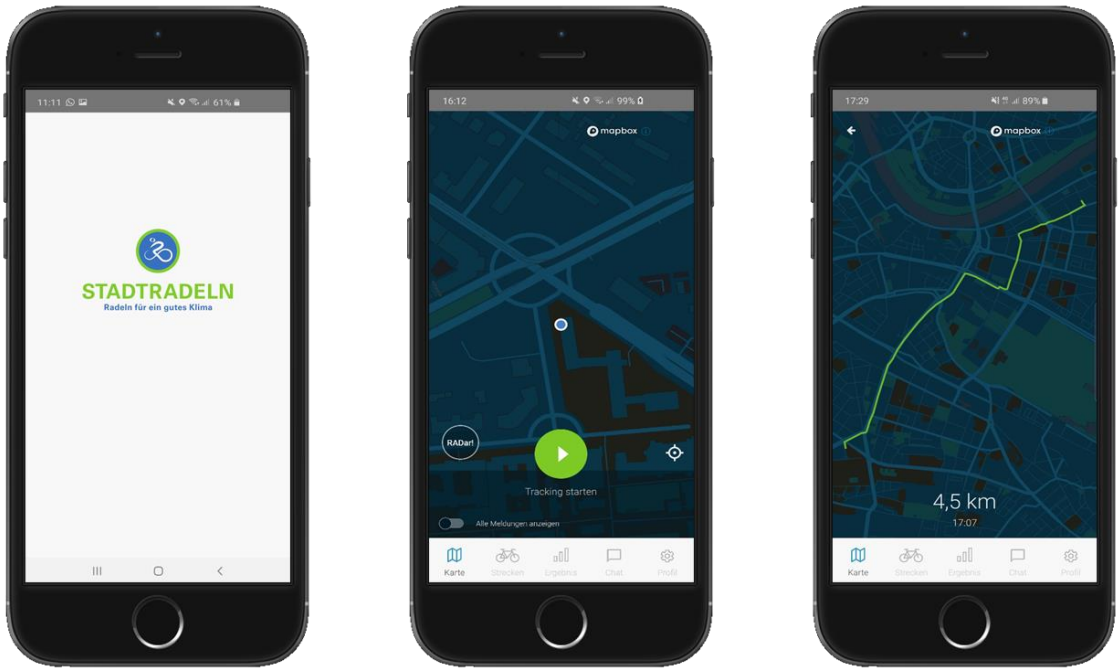


Abbildung 17: Die STADTRADELN-App

Um an der Aktion STADTRADELN teilnehmen zu können, mussten sich die Radfahrenden vorab auf der Website des STADTRADELN oder über die STADTRADELN-App registrieren. Sowohl bei der Registrierung als auch während der Aufzeichnung der gefahrenen Routen wurden Daten erhoben, die für die Arbeit von großer Relevanz sind.

Zum einen wurden personenbezogene Daten der Teilnehmenden erhoben, die für die Registrierung und Teilnahme am STADTRADELN sowie die Nutzung der App notwendig waren. Es wurden Vorname, Nachname, E-Mail-Adresse, Benutzername, ein Passwort, Alter, Geschlecht, Parlamentarier-Status, die zugehörige Kommune sowie eine Teamzugehörigkeit bei der Registrierung abgefragt. Die Informationen zu Alter, Geschlecht und Kommune sind für die vorliegende Arbeit von besonderer Bedeutung. Die Daten lassen einerseits eine Beschreibung der Teilnehmenden zu. Des Weiteren können die Daten über einen Identifikator (eindeutige ID) mit den aufgezeichneten Routen verknüpft werden. Die Erhebung dieser Daten erfolgte bei der Registrierung der Nutzer*innen über die STADTRADELN-Website bzw. STADTRADELN-App. Die Daten wurden durch die Teilnehmenden selbst eingegeben.

Darüber hinaus wurden über die Aufzeichnungskomponente der App eine Vielzahl von Daten erhoben, die von den im Smartphone verbauten Sensoren erzeugt werden. Dazu gehören GPS-Daten, mit denen die gefahrenen Routen räumlich verortet werden, sowie Daten weiterer Sensoren (bspw. des Beschleunigungssensors, des Magnetometers und des Gyroskops), die für die vorliegende Arbeit zu vernachlässigen sind. Tabelle 4 gibt einen Überblick über die erhobenen und genutzten Sensordaten.

| **Daten** | **Erläuterung** |
|---|---|
| Device-ID | Eindeutiger Identifikator des Aufzeichnungsgeräts (Smartphone) |
| Track-ID | Identifikator zur Bestimmung einer aufgezeichneten Fahrt |
| Punkt-ID | Identifikator eines GPS-Punkts |
| GPS_time | Datum und Zeit der Aufzeichnung eines GPS-Punkts |
| Lat | Latitude – geometrische Angabe zur Breitengrad-Position |
| Lon | Longitude – geometrische Angabe zur Längengrad-Position |
| Accuracy | Angabe zur Genauigkeit bzw. zum Fehlerbereich der Position |
| Measurement_fk | Identifikator einer einzelnen Messungen auf einer Device |

Tabelle 4: Von der Aufzeichnungskomponente der App übermittelte Daten

Durch das Einloggen der Teilnehmenden in der App konnten die Radfahrenden eindeutig mit dem Smartphone (Device-ID), mit dem sie ihre Strecken aufgezeichnet haben, verknüpft werden. Über die Device-ID einer aufgezeichneten Fahrt (siehe Tabelle 4) ist ein Rückschluss auf die Radfahrenden und ihre Eigenschaften (Alter und Geschlecht) möglich.

Die Nutzer*innendaten wurden beim Klima-Bündnis gespeichert und lediglich in Form von anonymisierten Nutzer*innendaten zu Forschungszwecken an die Technische

Universität Dresden (TUD) übermittelt. Die vom Klima-Bündnis erhobenen und übermittelten Sensordaten wurden auf separaten Servern gespeichert, die von der TUD betreut wurden. Da es sich bei den erhobenen Daten um personenbeziehbare Daten handelt – vor allem die GPS-Daten lassen über die Verortung von Fahrtbeginn und -ende das Herstellen eines Personenbezugs zu – mussten alle Proband*innen ihr Einverständnis bezüglich der Erhebung und Verarbeitung ihrer personenbezogenen Daten erklären.

Alle Prozesse mit Bezug zu personenbezogenen oder personenbeziehbaren Daten fanden entsprechend der datenschutzrechtlichen Vorgaben der Europäischen Union (EU-DSGVO), des Bundes (BDSG) und der Länder (HDSG, SächsDSG) statt. Zur Gewährleistung der Datensicherheit wurden angemessene personelle, technische und organisatorische Maßnahmen ergriffen, um eine den datenschutzrechtlichen Vorgaben nach Art. 5 und 32 EU-DSGVO, §9 BDSG, §10 HDSG und §10 SächSDSG entsprechende Datensicherheit zu gewährleisten.

#### 4.2.1.2 Datenaufbereitung

Eine anfangs manuell durchgeführte Plausibilisierung der erhobenen Daten ergab, dass bei der Datenerhebung durch die Proband*innen zwei wesentliche Fehler auftauchten. Zum einen vergaßen die Proband*innen häufig das Tracking am Ende ihrer Fahrt zu beenden. Dies führte dazu, dass nicht nur Fahrten aufgezeichnet wurden, sondern die Aufzeichnung auch während anderweitiger Aktivitäten (z.B. im Büro oder beim Einkaufen) fortgeführt wurde. Zum anderen tauchten in den Daten Fahrten auf, die offensichtlich nicht mit dem Fahrrad durchgeführt wurden (z.B. Fahrten mit Verkehrsmitteln des ÖPNV).

Da die beschriebenen Fälle sehr häufig auftauchten, wurde von einer manuellen Plausibilisierung der Daten abgesehen, weil diese in Anbetracht der großen Datenmengen (siehe Kapitel 5) nicht realisierbar gewesen wäre. Aus diesem Grund wurde eine systematische Methode zur Datenaufbereitung entwickelt und in der Programmiersprache Python umgesetzt. Da eine detaillierte und vollständige Beschreibung der entwickelten Datenaufbereitung den Umfang des vorliegenden Kapitels sprengen würde, wird die Funktionsweise der Datenaufbereitung im Folgenden verkürzt beschrieben. Eine ausführliche Beschreibung kann dem Anhang 2 entnommen werden.

Die Aufbereitung der hochgeladenen GPS-Daten erfolgte in mehreren Stufen (siehe Abbildung 18). Dazu wurde teils auf die in den GPS-Tracks enthaltenen Informationen (siehe Tabelle 4) zurückgegriffen; teilweise wurden aus diesen neue Informationen berechnet und genutzt.

Abbildung 18: Schritte der Primärdatenaufbereitung

Zu Beginn der Datenaufbereitung wurden die einzelnen Punkte eines GPS-Tracks zunächst in eine chronologische Reihenfolge gebracht. Diese war in den Daten nicht immer gegeben und hätte im weiteren Verlauf zu Fehlern in der Aufbereitung geführt.

Da viele der Teilnehmenden die STADTRADELN-App offensichtlich kurz ausprobierten, wurden auch sehr kurze GPS-Tracks hochgeladen, die keine Fahrten darstellten. Aus diesem Grund wurden über einen initialen Filter alle GPS-Tracks aus dem Datensatz verworfen, die weniger als 30 Punkte beinhaltete bzw. deren Aufzeichnungsdauer geringer als 30 Sekunden war.

In einem anschließenden Filter wurden alle Punkte eines GPS-Tracks mit einer Lagegenauigkeit von weniger als 35 m verworfen, weil diese „räumlichen Ausreißer“ einer Route die Verortung der Fahrten stark verzerrt und später angewandte Methoden (z.B. Map Matching; siehe Kapitel 4.2.4) beeinflusst hätten.

Die manuelle Plausibilisierung der GPS-Tracks ergab zudem, dass es während der Aufzeichnung von Fahrten häufig zum Verlust von GPS-Punkten und damit Teilen der Route kam. Daher wurde in einem weiteren Filter die Distanz zwischen dem ersten und letzten Punkt der entstehenden Lücken berechnet und ihr Anteil an der Gesamtstrecke eines Tracks bestimmt. War dieser größer als 10 % der Gesamtlänge eines Tracks (relativer Grenzwert) oder, unabhängig von der Gesamtlänge eines Tracks, mehr als 500 Meter (absoluter Grenzwert), so wurde ein Track verworfen.

In einem weiteren Schritt wurde eine Glättung der Geschwindigkeiten durchgeführt. Dabei geht es vor allem darum, Ausreißer zu nivellieren, weil korrekte Geschwindigkeitswerte ohne Ausreißer im weiteren Verlauf der Datenaufbereitung notwendig waren. Die Glättung der Geschwindigkeiten führt dazu, dass der Geschwindigkeitsverlauf „weicher“ wird. Die Glättung birgt große Vorteile für die Dateninterpretation und die weiteren Berechnungen. Für die Glättung wurde die Gauß‘sche Glättung genutzt, die Gewichte entsprechend einer Normalverteilung ausgehend vom Berechnungspunkt verteilt (siehe Anhang 2).

Die Analyse der hochgeladenen GPS-Tracks hat zudem aufgezeigt, dass viele der GPS-Tracks teils mehrere Fahrten und/oder weitere Aktivitäten beinhalteten. Der Grund ist vermutlich, dass die App-Nutzenden zum Fahrtende vergaßen, die Aufnahme zu stoppen. Durch das fortlaufende Tracking wurden fortwährend GPS-Punkte an den Aktivitäten-Orten aufgezeichnet, was die Datengrundlage wesentlich beeinflusste. Abbildung 19 zeigt

beispielhaft, wie sich ein derartiges Ereignis auf die Ergebnisse der aufgezeichneten Daten auswirkt.

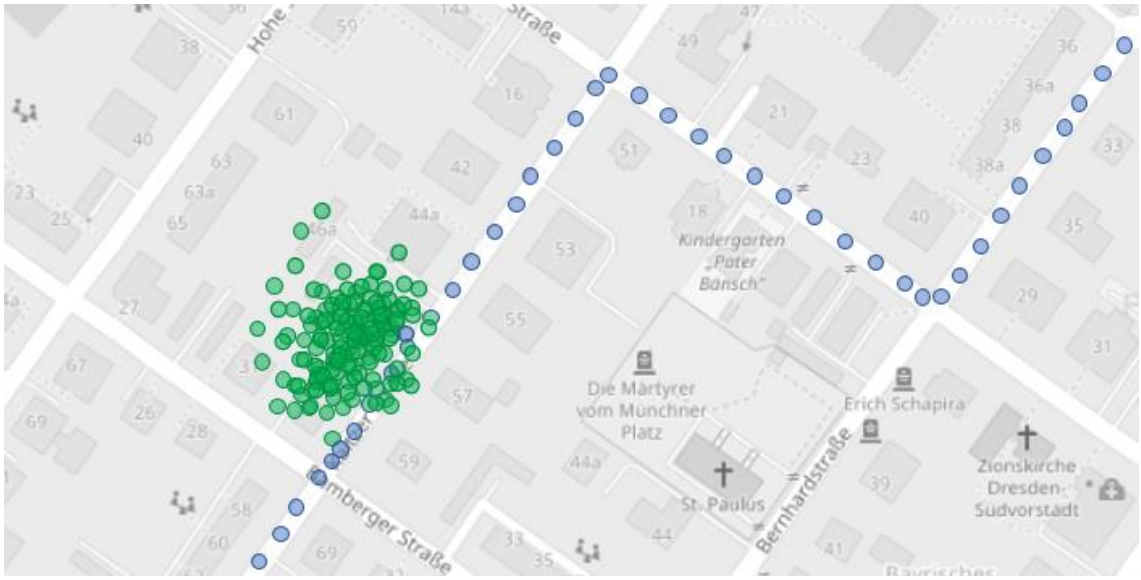


Abbildung 19: Punkte einer aufgezeichneten Fahrt (blau) inkl. Zwischenhalt (grün) an einem Aktivitäten-Ort

Ein dauerhaft fortgesetztes Tracking führt dazu, dass der aufgezeichnete GPS-Track zwei Fahrten und eine Aktivität beinhaltet, die als solche zwar visuell erkennbar sind. Da eine manuelle und visuelle Prüfung der erhobenen Daten bei zehntausenden GPS-Datensätzen jedoch nicht realisierbar ist, müssen diese Fahrten und Aktivitäten im Rahmen einer automatisierten Datenaufbereitung erkannt werden.

Darüber hinaus kann das fortgesetzte Tracking dazu führen, dass neben der eigentlichen Radfahrt auch Fahrten mit anderen Verkehrsmitteln (z.B. bei der Kombination von Fahrrad und ÖV) mit aufgezeichnet und übertragen wurden. Aus diesem Grund musste im Rahmen der Datenaufbereitung eine Überprüfung und, wenn nötig, Segmentierung des GPS-Tracks in Fahrten und Aktivitäten sowie eine Bestimmung des Verkehrsmittels Fahrrad innerhalb der erkannten Fahrten erfolgen.

Für die einzelnen Entscheidungsprozesse wurden komplexere Modelle genutzt, die in Anhang 2 ausführlich beschrieben sind. Abbildung 20 verbildlicht den Prozess vereinfacht. Die entwickelten Heuristiken basieren im Wesentlichen auf Kennwerten und Modellen, die aus der Datenanalyse hervorgegangen sind. Die Track-Segmentierung basiert im Wesentlichen auf den Geschwindigkeiten, den zurückgelegten Distanzen und der Änderung der Richtungsvektoren zwischen den GPS-Punkten. Die Verkehrsmittelerkennung bezieht Umwegefaktoren, unterschiedliche Geschwindigkeitsperzentile sowie die zurückgelegten Distanzen einer Fahrt ein. Die detaillierte Darstellung der entwickelten Methoden kann dem Anhang 2 entnommen werden.

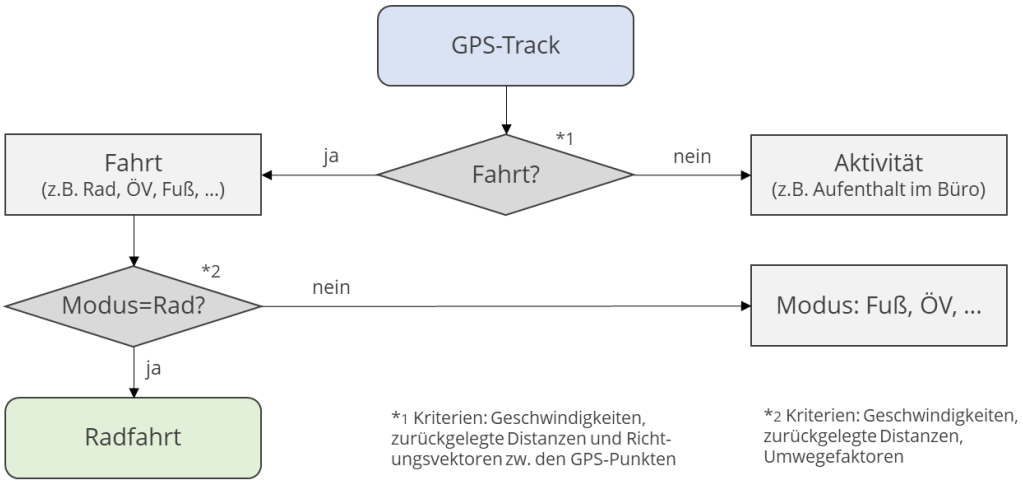


Abbildung 20: Vereinfachte Veranschaulichung der Entscheidungsprozesse zur Erkennung von Radfahrten im GPS-Datensatz

Nach der Segmentierung der Tracks sowie der Erkennung der Verkehrsmittel wird über die Modi gefiltert, sodass ein bereinigter Datensatz zur Verfügung steht, der lediglich Radfahrten beinhaltet. Die Datenaufbereitung wurde mit einem zufällig ausgewählten und manuell plausibilisierten Datensatz getestet. Es erfolgte anschließend in mehreren Schleifen eine Validierung und iterative Anpassung der Kennwerte, sodass GPS-Tracks kaum fehlerhaft segmentiert und Fahrten keinem falschen Verkehrsmittel zugeordnet wurden. Die Genauigkeit der Verkehrsmittelerkennung lag schließlich bei rund 88 %.

Mit einem letzten Filter wurden schließlich Fahrten aus dem Datensatz bereinigt, die aufgrund technischer Restriktionen bei der Implementierung der Track-Segmentierung entstanden. Hintergründe und Umsetzung sind ebenfalls in Anhang 2 beschrieben.

Das Ergebnis der Primärdatenaufbereitung sind bereinigte GPS-Daten, die nur noch Radfahrten beinhalten. Sie stehen von diesem Zeitpunkt an für weitere Schritte zur Verfügung.

### 4.2.2 Sekundärdatenaufbereitung

Um den Einfluss der unterschiedlichsten Faktoren auf die Routenwahl analysieren zu können, ist eine große Menge von Sekundärdaten zur Abbildung der Einflussfaktoren notwendig. In Kapitel 3 wurde bereits aufgezeigt, dass zahlreiche Einflussfaktoren existieren, die die Routenwahl von Radfahrenden beeinflussen. Das Portfolio möglicher Einflussfaktoren wurde bereits mehrfach in anderen Studien erarbeitet. Auf die Herleitung einer Liste mit Einflussfaktoren wird aus diesem Grund an dieser Stelle verzichtet und auf Kapitel 3 verwiesen.

Auf Basis der in Kapitel 3 recherchierten Studien wurden die folgenden Einflussfaktoren festgelegt, die in die Analyse der vorliegenden Arbeit aufgenommen werden:

a) Distanz und/oder Reisezeit
b) Längsneigung
c) Radverkehrsführungsform
d) Breite der Radverkehrsführung
e) Oberflächenbeschaffenheit
f) Radverkehrsstärke
g) Kraftfahrzeugverkehrsstärke
h) Fahrstreifenanzahl
i) Zulässige Höchstgeschwindigkeit des Kfz-Verkehrs
j) Ruhender Verkehr
k) Sicherheitsraum
l) Sicherheit
m) Knotenpunkte und deren Regelung
n) Flächennutzung
o) Alter und Geschlecht der Radfahrenden

Die Liste der benannten Einflussfaktoren ist umfangreich (n=18). Um die aufgeführten Einflussfaktoren in die Analysen zu integrieren, ist eine Vielzahl unterschiedlicher Daten notwendig. Die benötigten Daten lagen teilweise schon vor und konnten damit aus bestehenden Quellen entnommen und aufbereitet werden (z.B. Daten aus dem Open Data Portal der Stadt Dresden). Teilweise lagen jedoch keine Informationen oder nur unvollständige Daten vor, sodass die benötigten Daten erhoben werden mussten. Es sei an dieser Stelle ausdrücklich auf das Forschungsprojekt „Sichere Routenwahl“ hingewiesen, in dessen Rahmen ein Großteil der Erhebungen durchgeführt wurden. In den folgenden Abschnitten wird auf die genutzten Daten, die Datenherkunft und deren Aufbereitung eingegangen.

#### a) Distanz und/oder Reisezeit

Die zurückgelegte Strecke einer Fahrt kann für jede Route sowie Routenalternative berechnet werden. Sie kann einen wesentlichen Einfluss auf die Routenwahl ausüben (siehe Kapitel 3). Die Distanz einer Route bzw. Routenalternative wird mit Hilfe des Netzmodells (siehe Kapitel 4.2.3) bestimmt. In diesem ist für jedes einzelne Streckenelement (Kante) eine Länge in Metern hinterlegt. Mit diesen Daten zur Länge der einzelnen Streckenabschnitte im Netz kann die Distanz einer Route/Routenalternative berechnet werden, weil für jede der Routen/-alternativen die im Netzt genutzten Kanten bekannt sind.[5]

[5] Beim Map Matching (siehe Kapitel 4.2.4) und der Erzeugung von Alternativrouten (siehe Kapitel 4.2.5) werden die IDs der genutzten Kanten gespeichert.

Für die Berechnung der Distanz *d* einer Route/Alternative *R* wird jeweils die Länge *s* der genutzten Kanten *k* abgerufen und aufsummiert (siehe Formel (11)).

$$d_R = \sum_{k=1}^{n} s_k \tag{11}$$

Im Ergebnis steht für jede gewählte Route sowie alle erzeugten Routenalternativen eine Gesamtlänge für die Analyse zur Verfügung.

Die Reisezeit wird als der Zeitaufwand definiert, der nötig ist, um eine Ortsveränderung zwischen zwei Punkten durchzuführen. Im Rahmen der vorliegenden Arbeit ist damit die Zeit definiert, die beim Zurücklegen einer Route/Routenalternative vom Start bis zum Ende einer Fahrt benötigt wird. Sie wird in Minuten angegeben und kann einen wesentlichen Einfluss auf die Routenwahl ausüben (siehe Kapitel 3). Für die vorliegende Arbeit kann zur Bestimmung der Reisezeit auf Informationen aus a) den Primärdaten sowie b) den erzeugten Routenalternativen zurückgegriffen werden. In den Primärdaten sind für jede Fahrt über die Zeitstempel der GPS-Punkte (siehe Kapitel 4.2.1) Informationen zum zeitlichen Beginn und Ende einer Fahrt enthalten. Die Reisezeit *t* einer Route *R* wird ermittelt, indem die Zeit des ersten ($t_1$) und letzten ($t_n$) Zeitstempels ausgelesen und die Zeitdifferenz berechnet wird. Die Berechnung folgt Formel (12).

$$t_R = t_n - t_1 \tag{12}$$

Die Reisezeit der Routenalternativen wird bei der Erzeugung der Routenalternativen ermittelt. Sie wird direkt von dem für das Erzeugen der Routenalternativen genutzte Programm (Graphhopper 2020) ausgegeben und basiert im Wesentlichen auf Annahmen zu verschieden realisierbaren Geschwindigkeiten auf unterschiedlichen Oberflächentypen und Steigungen (GitHub 2020). So wird in Abhängigkeit von den Eigenschaften eines Streckensegments jeweils eine segmentbezogene Geschwindigkeit bestimmt und eine daraus resultierende Reisezeit ermittelt. Die Gesamtzeit *t* einer Routenalternative *RA* ergibt sich damit aus der Summe aller Teilreisezeiten $t_i$ der einzeln Elemente nach Formel (13).

$$t_{RA} = \sum_{i=1}^{n} t_i \tag{13}$$

Im Ergebnis stehen am Ende der Aufbereitung für jede Route bzw. Alternative eine Reisezeit in Minuten zur Verfügung.

### b) Längsneigung

Die Längsneigung ist sowohl bei der Ausgestaltung der Radverkehrsanlagen als auch bei der Routenwahl ein wichtiges Kriterium im Radverkehr. So soll bspw. nach FGSV 2010 die Längsneigung an Rampen von Unter- bzw. Überführungen möglichst nicht über 3-4 % liegen. Bei Steigungen, die sich z.B. bedingt durch die Topographie ergeben, lassen sich derartige maximale Längsneigungen jedoch nicht immer realisieren. Die Längsneigung ist zudem ein wesentlicher Einflussfaktor der Routenwahl, weil mit zunehmender Längsneigung die Anstrengung der Radfahrenden zur Überwindung der Steigung größer wird und dies den Komfort verringert und die physische Belastbarkeit von Radfahrer*innen übersteigen kann.

Zur Bestimmung der Längsneigung der Streckenabschnitte wird auf Daten des Digitalen Geländemodells (DGM) für Sachsen zurückgegriffen. Die Daten des DGM basieren auf Daten der Shuttle Radar Topography Mission (SRTM) der NASA (NASA-b 2020). Die Höhendaten liegen in unterschiedlichen Auflösungen vor und sind frei verfügbar und zugänglich. Für Dresden wird ein DGM mit einer Maschenweite von 2 m verwendet. Das bedeutet, dass für Dresden ein Rasterdatensatz mit einer Auflösung von 2 m zur Verfügung steht, bei dem jedem Raster ein konkreter Höhenwert zugwiesen ist. Der Datensatz wurde über das Online-Portal des Staatsbetriebs Geobasisinformation und Vermessung Sachsen abgerufen (GeoSN 2020).

Die Höhenwerte können genutzt werden, um die Längsneigung der einzelnen Kanten im Netzmodell zu berechnen. Dazu werden zunächst die Höhendaten aus dem DGM von den Rasterzellen auf die Knoten bzw. Stützpunkte der Kanten im Netzmodell übertragen. Die Höhen für jeden Stützpunkt entlang der gefahrenen Route sind durch die Zuweisung der Routen zu den Kanten (siehe Kapitel 4.2.6) aus dem DGM bekannt. Die Längsneigung $LN$ einer Kante $K$ ergibt sich aus der Höhendifferenz $\Delta h_{ij}$ zwischen zwei aufeinanderfolgender Knoten-/Stützpunkten $i$ und $j$ (abhängig von ihrer jeweiligen Höhe $h_i$ bzw. $h_j$) und der Länge $l$ der Kante $k$ nach Formel (14).[6]

$$LN_k = \frac{\Delta h_{ij}}{l_k} = \frac{h_j - h_i}{l_k} \tag{14}$$

Die Längsneigung kann, in Abhängigkeit von der Fahrtrichtung, positive und negative Werte annehmen. Im Ergebnis der Berechnungen stehen für jede Kante im Netzmodell Werte zur Längsneigung zur Verfügung.

[6] Anmerkung: Es wird die Steigung, nicht der Steigungswinkel, berechnet und genutzt. Der Steigungswinkel wäre über trigonometrische Funktionen zu bestimmen.

### c) Radverkehrsführungsform

Der Radverkehr wird in unterschiedlichen Formen geführt. Wesentliche Führungsformen sind bspw. Radfahr- oder Schutzstreifen, baulich getrennte Radwege, selbständig geführte Radwege oder gemeinsam genutzte Wege (Rad- und Fußverkehr) usw. (vgl. FGSV 2010). Da die Radverkehrsführungsform einen wesentlichen Einfluss auf die Routenwahl im Radverkehr haben kann (siehe Kapitel 3), sollten möglichst alle relevanten Ausprägungen der Führungsform in die Analysen einbezogen werden.

Da von der Stadt Dresden keine Daten zur Radverkehrsführungsform bezogen werden konnten und sich andere Datenquellen (bspw. OpenStreetMap) bei einer genauen Prüfung als teils nicht aktuell und zuverlässig erwiesen, wurden die Radverkehrsführungsformen erhoben. Ausgangspunkt der Erhebung war eine Hausmitteilung der Stadt Dresden zum Radverkehr auf Geh- und Radwegen (Basisinformation), die durch Erhebungen aktualisiert und ergänzt wurde. Die Erhebung erfolgte via Satellitenbilder (Google Earth), Google Street View und teilweise Ortsbegehungen. Es wurden folgende Führungsformen aufgenommen:

- Mischverkehr
- Mischverkehr mit Schutzstreifen
- Radfahrstreifen
- Bussonderfahrstreifen mit Freigabe für den Radverkehr
- Radweg
- Gemeinsamer Geh- und Radweg
- Selbstständige gemeinsame Geh- und Radwege
- Selbstständige getrennte Geh- und Radwege
- Selbstständige Gehwege

Im Rahmen der Datenaufbereitung wurden die Führungsformen den entsprechenden Kanten im Angebotsnetz zugewiesen. Ergebnis der Arbeit ist ein Netzmodell, in dem für alle Streckenabschnitte des Hauptverkehrsstraßennetzes eine Ausprägung des Attributs „Radverkehrsführungsform“ besitzen. Die Ausprägung entspricht den oben genannten Klassen. Auf die Nutzung der aufbereiteten Daten zur Berechnung der Eigenschaften der Routen/-alternativen wird in Kapitel 4.2.6 eingegangen.

### d) Breite der Radverkehrsführung

Die Breite der Radverkehrsführung ist ein planerisches Grundmaß für die Gestaltung der Verkehrsräume des Radverkehrs (FGSV 2010). Unter „Breite der Radverkehrsführung“ wird in der vorliegenden Arbeit die Breite der Führung je Fahrtrichtung verstanden, die dem Radfahrenden im Falle einer eigenen Führung zur Verfügung steht. Die Breite der

Radverkehrsanlage schließt, in Anlehnung an die Empfehlungen der ERA, die Markierung mit ein. Die Zusammenhänge zwischen Licht-, Verkehrs- und Sicherheitsraum sind ausführlich in der ERA beschrieben (FGSV 2010).

Zur Beschreibung der Breite der Führungsform lagen zum Zeitpunkt der Durchführung der Arbeit keine Daten vor, sodass die Informationen für die einzelnen Streckenabschnitte erhoben werden mussten. Für die Erhebung wurde hauptsächlich auf Informationen aus Luft- und Satellitenbilder (Google Earth) zurückgegriffen. War zum Erhebungszeitpunkt auf einem Streckenabschnitt eine eigene Führung für den Radverkehr (außer Mischverkehr) vorhanden, so wurde dessen Breite gemessen und aufgenommen. Die Messung erfolgte anhand der Luft-/Satellitenbilder in QGIS mit der Funktion "Distanz messen", die eine zentimetergenaue Vermessung der Breite der Radverkehrsführungsform zulässt. Die wesentliche Limitierung in Bezug auf die Genauigkeit der Erhebung bestand bei der Messung vor allem in der Auflösung der Satelliten- und Luftbilder sowie deren Interpretation.

Ergebnis der Erhebung ist, dass für alle Kanten des Hauptverkehrsstraßennetzes Ausprägungen zum Attribut „Breite der Radverkehrsführungsform“ zur Verfügung stehen. Die Breite ist in Metern [m] angegeben. Auf die Nutzung der aufbereiteten Daten zur Berechnung der Eigenschaften der Routen/-alternativen wird in Kapitel 4.2.6 eingegangen.

#### e) Oberflächenbeschaffenheit

Die Oberflächenbeschaffenheit ist vor allem in Hinblick auf den Fahrkomfort von hoher Relevanz. Dies betrifft vor allem die Qualität der baulichen Ausführung der Deckschicht, die möglichst eine *„ebene Oberfläche mit möglichst geringem Rollwiderstand“* (FGSV 2010, S. 76) bieten soll. In der Praxis existieren unterschiedliche Oberflächentypen (z.B. Asphalt, Pflaster, Kopfsteinpflaster oder unbefestigte Oberflächen), die maßgeblich den Fahrkomfort beeinflussen. Die Beschaffenheit der Oberflächen ist daher ein relevanter Einflussfaktor der Routenwahl im Radverkehr, weil sie einen wesentlichen Einfluss auf die Wahrnehmung von Komfort beim Radfahren ausüben kann (siehe Kapitel 3).

Zur Abbildung der Oberflächenbeschaffenheit von Radverkehrsanlagen liegen nur wenig verlässliche Daten vor. Informationen können bspw. aus den Daten des OpenStreetMap-Projekts (OSM) extrahiert werden (OSM 2019). Die Überprüfung der Daten ergab jedoch, dass die realen Zustände der Oberflächenbeschaffenheit in den OSM-Daten nur teilweise korrekt wiedergegeben werden. Aufgrund der unzureichenden Qualität wurde von der Nutzung der OSM-Daten abgesehen. Um die Oberflächenbeschaffenheit der Stre-

ckensegmente korrekt zu bestimmen, wurden Informationen zu den Oberflächen erhoben. Die Erhebung erfolgte über Satellitenfotos (Google Earth), Google Street View, Google Earth und teilweise auch Ortsbegehungen.

Die erhobenen Oberflächen wurden im Angebotsmodell hinterlegt und den entsprechenden Netzkanten zugewiesen. Im Ergebnis besitzen alle Kanten des Hauptverkehrsstraßennetzes eine der folgenden Ausprägungen des Attributs:

- Asphalt
- Pflaster
- Kopfsteinpflaster
- Natur, gebunden
- Natur, ungebunden
- k.A. (keine Angabe)

Auf die Nutzung dieser aufbereiteten Daten zur Berechnung der Eigenschaften der Routen und Routenalternativen wird in Kapitel 4.2.6 eingegangen.

#### f) Radverkehrsstärken

Die Radverkehrsstärken bzw. Verkehrsmengen im Netz können ebenfalls einen Einfluss auf die Routenwahl ausüben. Fahren auf stark frequentierten Strecken kann bspw. die subjektive Sicherheit erhöhen oder auch störend wirken (siehe Kapitel 3). Zur aggregierten Abbildung der Radverkehrsmengen eignet sich vor allem der durchschnittlich tägliche Verkehr des Radverkehrs ($DTV_{Rad}$).

Zur realistischen Abbildung eines stadtweiten $DTV_{Rad}$ wurde auf unterschiedliche Datenquellen zurückgegriffen und diese kombiniert. Dazu wurde auf Zähldaten der Dauerzählstellen der Stadt Dresden zurückgegriffen (LH-Dresden-e 2019). Sie geben Auskunft über die Radverkehrsstärken an den unterschiedlichen Querschnitten im Netz. Diese punktuellen Informationen reichen jedoch nicht aus, um den $DTV_{Rad}$ stadtweit abzubilden.

Um einen stadtweiten $DTV_{Rad}$ zu erhalten, der möglichst alle Elemente des Verkehrsnetzes abdeckt, wurden die Verkehrsmengen der GPS-Daten mit den Verkehrsmengen aus den Zähldaten an den Zählquerschnitten korreliert. Dafür wurde zunächst für jeden Querschnitt der Dauerzählstellen der durchschnittlich tägliche Verkehr innerhalb des Erhebungszeitraum berechnet. Anschließend wurden die Fahrten aus den GPS-Daten zu Verkehrsmengen aufsummiert und die Werte der Verkehrsstärke für die entsprechenden Querschnitte an den Dauerzählstellen entnommen. In einem letzten Schritt wurde eine einfache lineare Regressionsanalyse durchgeführt und analysiert, ob ein Zusammenhang zwischen dem $DTV_{Rad}$ der Dauerzählstellen und den Verkehrsstärken aus den GPS-Daten existiert. Die Regression zeigte mit $R^2 = 0{,}83$ ein sehr gutes Ergebnis (siehe Anhang 3).

Über die ermittelte Regressionsgleichung und die Verkehrsmengen im GPS-Datensatz kann durch Hochrechnung ein netzweiter $DTV_{Rad}$ berechnet werden. Damit besitzen alle Kanten im Netzmodell, die mit Radfahrten aus dem GPS-Datensatz belastet waren, eine Ausprägung des Attributs $DTV_{Rad}$. Auf die Nutzung der aufbereiteten Daten zur Berechnung der Eigenschaften der Routen/-alternativen wird in Kapitel 4.2.6 eingegangen.

#### g) Kraftfahrzeugverkehrsstärke

Die Verkehrsstärken des motorisierten Verkehrs (MV) stellen sowohl bei der Anlage von Radverkehrsanlagen (FGSV 2010) als auch bei der Routenwahl (siehe Kapitel 3) ein wesentliches Kriterium dar. Dies ist insbesondere auf das zunehmende Gefährdungspotential der Radfahrenden mit steigender Verkehrsstärke zurückzuführen (siehe FGSV 2010), aber auch auf die Zunahme von Lärm, Emissionen usw., die den Fahrkomfort negativ beeinflussen können. Zur Abbildung der Verkehrsstärken motorisierten Verkehrs wurde auf den durchschnittlich täglichen Verkehr (DTV) zurückgegriffen. Der DTV gibt den Fahrzeugdurchsatz an einem Tag an (Lemke 2015).

Als Datengrundlage konnte auf Informationen der Stadt Dresden zurückgegriffen werden. Die durch das Straßentiefbauamt (STA) der Stadt zur Verfügung gestellten Informationen beinhalten sowohl Daten aus temporären Knotenstromzählungen (Kurzzeitzählung) als auch Daten aus kontinuierlichen Zählungen (Erhebung über Induktionsschleifen). Die übermittelten Daten enthielten bereits Informationen zum DTV an den entsprechenden Knoten und Querschnitten. Die Verkehrsstärken wurden auf die anliegenden Kanten (bei Knotenstromzählungen) umgelegt bzw. direkt mit den Kanten des Angebotsnetzes verknüpft (bei Querschnittszählungen). Es erfolgte zusätzlich ein Abgleich mit den DTV-Werten aus dem Themenstadtplan der Stadt (LH-Dresden-g 2020), um mögliche Fehlstellen zu identifizieren, Daten zu ergänzen und somit eine stadtweite Abdeckung zu erreichen.

Im Ergebnis konnte damit eine kantenfeine Zuordnung des $DTV_{Kfz}$ für alle Kanten im Hauptverkehrsstraßennetz realisiert werden. Die Werte der Attribute wurden im Netzmodell hinterlegt. Auf die Nutzung der aufbereiteten Daten zur Berechnung der Eigenschaften der Routen/-alternativen wird in Kapitel 4.2.6 eingegangen.

#### h) Fahrstreifenanzahl

Die Anzahl der Fahrstreifen für den Kfz-Verkehr ist laut ERA ebenfalls bei der Anlage von Radverkehrsanlagen zu berücksichtigen (siehe FGSV 2010) und spielt auch in der Routenwahl eine wesentliche Rolle (siehe Kapitel 3). So kann bspw. das Sicherheitsempfinden

der Radfahrenden insbesondere bei der Führung im Mischverkehr stark von der Anzahl der Fahrstreifen abhängig sein.

Aufgrund des Fehlens vorhandener Daten wurde die Anzahl der Fahrstreifen über Luft- und Satellitenbilder (Google Earth) erhoben. Die Erhebung erfolgte über einen einfachen visuellen Abgleich (Zählen der Fahrsteifen auf den Streckenabschnitten). Die erfassten Informationen wurden anschließend mit den Kanten des Netzmodells verknüpft und im Netzmodell hinterlegt.

Ergebnis der Datenerhebung und -aufbereitung ist, dass für alle Kanten des Hauptverkehrsnetzes Informationen zur Anzahl der Fahrstreifen im Netzmodell vorliegen. Alle Kanten besitzen damit eine Ausprägung des Attributs „Anzahl der Fahrstreifen“ (Angabe als absolute Anzahl). Auf die Nutzung der aufbereiteten Daten zur Berechnung der Eigenschaften der Routen/-alternativen wird in Kapitel 4.2.6 eingegangen.

#### i) Zulässige Höchstgeschwindigkeit des MV

Die auf den Streckenabschnitten maximal zulässige Geschwindigkeit für den motorisierten Verkehr ist eine wesentliche Bemessungsgrundlage bei der Anlage von Radverkehrsanlagen (FGSV 2010). Die Geschwindigkeiten des fließenden MV können zudem einen relevanten Einfluss auf die Routenwahl haben. Wesentlich scheinen dabei vor allem die Differenzgeschwindigkeiten zwischen Radverkehr und motorisiertem Verkehr sowie deren Wahrnehmung zu sein (siehe Kapitel 3). Insofern sind die tatsächlich realisierten Geschwindigkeiten des MV und des Radverkehrs auf gemeinsamen genutzten Streckenabschnitten wichtige Eingangsgrößen für die Analyse.

Da Informationen zu den durchschnittlich realisierten Geschwindigkeiten des MV auf den Streckenabschnitten jedoch nicht vorlagen und aufgrund des Umfangs einer möglichen Erhebung auch nicht erfasst werden konnten, wurde auf die maximal zulässige Geschwindigkeit des MV zurückgegriffen. Als Datengrundlage wurden die Informationen des OSM-Netzes (tag *„maxspeed“*) genutzt, weil sich die Qualität der dort hinterlegten Informationen bei der Überprüfung der Daten als zuverlässig herausstellten. Die Daten wurden anhand weiterer Informationen (Bilddaten und Begehungen) validiert und teils ergänzt oder korrigiert.

Im Ergebnis liegen für alle Streckenabschnitte Informationen zur maximal zulässigen Geschwindigkeit des motorisierten Verkehrs vor. Um die Daten möglichst konsistent und übersichtlich zu halten und nicht unzählige Ausprägungen und Sonderfälle zu berücksichtigen, wurden die nachfolgenden fünf Klassen gebildet:

- $v_{zul}$ < 6 km/h
- $v_{zul}$ = 6-30 km/h
- $v_{zul}$ = 30-50 km/h
- $v_{zul}$ > 50 km/h
- k.A.

Auf die Nutzung der aufbereiteten Daten zur Berechnung der Eigenschaften der Routen/-alternativen wird in Kapitel 4.2.6 eingegangen.

**j) Ruhender Verkehr**

Der ruhende Verkehr kann als Gegenstück zum fließende Verkehr angesehen werden. Er umfasst sowohl das Halten (gewollte Fahrtunterbrechung) als auch das Parken von Fahrzeugen im öffentlichen Straßenraum (Fliegauf 1994). Flächen des ruhenden Verkehrs werden u.a. nach Art der Fahrzeugaufstellung unterschieden (z.B. längs oder quer zur Fahrbahn) (FGSV 2005). Entsprechend der Fahrzeugaufstellung und der damit einhergehenden Ausrichtung der Kraftfahrzeuge birgt der ruhende Verkehr auch Gefahren für den fließenden Radverkehr (Stichwort „Dooring“). Der ruhende Verkehr birgt dadurch das Potential das Sicherheitsempfinden der Radfahrenden zu senken. Dass im ruhenden Verkehr ein relevanter Einflussfaktor der Routenwahl besteht, zeigt auch die Literatur auf (siehe Kapitel 3).

Zum Zeitpunkt der Durchführung der Studie existierten keine stadtweiten Daten zur Abbildung des ruhenden Verkehrs im Untersuchungsgebiet. Aus diesem Grund wurden Daten zum ruhenden Verkehr erhoben und aufbereitet. Die Erhebung stützte sich maßgeblich auf Informationen aus Satellitenbildern (Google Earth). Während der Erhebung wurden alle Flächen des ruhenden Verkehrs entlang des Hauptverkehrsnetzes erfasst und den folgenden Aufstellarten zugeordnet:

- Längs
- Schräg
- Quer
- Kombination
- k.A.

Die erfassten und kategorisierten Flächen wurden mittels QGIS räumlich verortet, sodass eine eindeutige Zuordnung der Aufstellflächen zu den Kanten in Netzmodell erfolgen konnte. Damit lagen am Ende der Aufbereitung für jede Kante Informationen über die Existenz von Flächen des ruhenden Verkehrs und deren Art der Fahrzeugaufstellung vor. Auf die Nutzung der aufbereiteten Daten zur Berechnung der Eigenschaften der Routen/-alternativen wird in Kapitel 4.2.6 eingegangen.

### k) Sicherheitsraum

Sicherheitsabstände zum fließenden und ruhenden Verkehr sind von hoher Relevanz im Radverkehr und können einen starken Einfluss auf die Wahl von Streckenabschnitten, und damit auch auf die Gesamtroute, ausüben. Dies wird maßgeblich auf das subjektive Sicherheitsempfinden zurückgeführt (siehe Kapitel 3). Sicherheitsabstände werden auch bei der Anlage von Radverkehrsanlagen berücksichtigt (FGSV 2010). Der Abstand der Radverkehrsanlage zum fließender Pkw-Verkehr (Fahrbahn) bzw. zum ruhenden Verkehr wird als Sicherheitsraum bezeichnet und z.B. durch das Markieren von Sicherheitstrennstreifen im Straßenraum gekennzeichnet (FGSV 2010).

Zum Zeitpunkt der Durchführung der Arbeit existierten keine stadtweiten Informationen zum Sicherheitsraum, sodass eine Erhebung der Daten notwendig war. Die Erhebung erfolgte in Analogie zur Erhebung der Breite der Radverkehrsführungsform. Zur Messung des Sicherheitsraumes wurden die Abstände zur Fahrbahn bzw. zum ruhendem Verkehr (wenn vorhanden) erhoben, wenn der Radverkehr im Seitenraum geführt wird. Darüber hinaus wurde die Breite des Sicherheitstrennstreifens zum ruhenden Verkehr gemessen, wenn der Radverkehr auf der Fahrbahn geführt wird.

Die Informationen wurden anschließend in dem Netzmodell hinterlegt, sodass für alle Kanten des Hauptverkehrsstraßennetzes eine Ausprägung der Attribute (in Metern) vorlag. Auf die Nutzung der aufbereiteten Daten zur Berechnung der Eigenschaften der Routen/-alternativen wird in Kapitel 4.2.6 eingegangen.

### l) Sicherheit

Der Sicherheit wird im Zusammenhang mit der Routenwahl ein signifikanter Einfluss zugeschrieben (siehe Kapitel 3). In Bezug zum Thema Sicherheit muss prinzipiell zwischen objektiver und subjektiver Sicherheit unterschieden werden. Während die objektive Sicherheit z.B. durch Unfallhäufigkeiten beschrieben werden kann, wird unter subjektiver Sicherheit vor allem die Wahrnehmung der Sicherheit durch die Radfahrenden verstanden. Insbesondere das subjektive Sicherheitsempfinden kann das Verkehrsverhalten beeinflussen (Hagemeister 2013).

Um die Sicherheit in die Analyse zu integrieren, wird auf unterschiedliche Datenquellen zurückgegriffen. Dies sind zum einen die Daten der polizeilichen Unfallaufnahme, die in den Unfalldaten der Europäischen Unfalltypensteckkarte (EUSKa) zusammengeführt sind. Sie ermöglichen die räumliche Verortung von Unfällen und Unfalltypen und werden für die Abbildung der objektiven Sicherheit genutzt. Die Daten sind bspw. über das Statistikportal des Bundes und der Länder frei zugänglich (Unfallatlas 2020). An dieser Stelle muss darauf hingewiesen werden, dass die objektive Sicherheit korrekterweise eher als

„objektive Unsicherheit“ betitelt werden müsste, weil eine ansteigende Unfallhäufigkeit eher auf ein geringeres Sicherheitsniveau hinweist.

Zur Abbildung der subjektiven Sicherheit werden Informationen aus den Mobilitätsberichten des Projekts RadVerS genutzt. In den Berichten liegen für den Raum Dresden 407 Meldungen zu kritischen Situationen und deren räumlicher Verortung im Straßenraum des Untersuchungsgebietes vor (siehe Becker und Petzoldt 2019).

Für die Analysen ist vor allem die räumliche Verortung der Unfallorte (objektive Sicherheit) und der Orte mit gemeldeten kritischen Situationen (subjektive Sicherheit) relevant. Dazu wurden die bereits verorteten Unfallstellen in QGIS importiert sowie die Orte mit kritischen Situationen in QGIS verortet. In einem weiteren Schritt wurden die Stellen den genutzten Kanten und Knotenpunkten zugewiesen.

Ergebnis der Aufbereitung sind Informationen zur Anzahl der Unfälle je Kante und Knotenpunkt sowie Informationen zu den Punkten subjektiver Sicherheit je Kante und Knotenpunkt. Auf die Nutzung der aufbereiteten Daten zur Berechnung der Eigenschaften der Routen/-alternativen wird in Kapitel 4.2.6 eingegangen.

**m) Knotenpunkte und deren Regelung**

Die Anzahl der zu passierenden Knotenpunkte entlang einer Route kann einen starken Einfluss auf die Wahl einer Route ausüben (siehe Kapitel 3). Dies wird in der Literatur vor allem darauf zurückgeführt, dass an Knotenpunkten zusätzliche Zeitverluste entstehen. Diese Zeitverluste können durch Wartevorgänge entstehen, die z.B. an Lichtsignalanlagen geregelten Knotenpunkten entstehen und so zu einer Erhöhung der Reisezeit führen. Darüber hinaus können Knotenpunkte, die durch eine LSA geregelt sind, jedoch auch zusätzliche Sicherheit beim Queren von Straßen mit hohem Verkehrsaufkommen bieten (siehe Kapitel 3).

Knotenpunkte können unterschiedlich geregelt sein. Es wird prinzipiell zwischen den Regelungsarten „Rechts-vor-Links“, Verkehrszeichengeregelt Z205 („Vorfahrt beachten“), Verkehrszeichengeregelt Z206 („STOP“) sowie Reglung mittels Teil-LSA, LSA oder Kreisverkehr unterschieden (FGSV 2006).

Zur Abbildung der Knotenpunkte und ihrer Regelung lagen zum Zeitpunkt der Arbeit keine umfangreichen und vollständigen Daten vor. Auf Basis von OpenStreetMap können zwar Daten zur räumlichen Lage der Knotenpunkte ermittelt werden. Die Art der Regelung der Knotenpunkte lässt sich indes nicht korrekt mit den OSM-Daten abbilden, da bspw. die Lichtsignalanlagen nicht den Knotenpunkten zugewiesen, sondern selbständig verortet sind. Da zur Regelungsart der vorliegenden Knotenpunkte keine Daten zur Verfügung

standen, wurden diese Informationen nacherhoben. Für die Erhebung wurden hauptsächlich Satellitenbilder (Google Earth) und Google-Streetview genutzt sowie teilweise Begehungen durchgeführt. Auf diese Weise wurde die Regelung an den Knotenpunkten erfasst und im Netzmodell hinterlegt.

Im Ergebnis lagen damit für jeden im Netzmodell vorhanden Knotenpunkt Informationen zur Regelungsart vor. Entsprechend der oben genannten Regelungsarten werden die Knotenpunkte wie folgt unterschieden:

- Rechts-vor-Links
- Verkehrszeichengeregelt Z205 („Vorfahrt beachten“)
- Verkehrszeichengeregelt Z206 („STOP“)
- Teil-LSA
- LSA
- Kreisverkehr

Auf die Nutzung der aufbereiteten Daten zur Berechnung der Eigenschaften der Routen/-alternativen wird in Kapitel 4.2.6 eingegangen.

#### n) Flächennutzung

Die Art der Flächennutzung entlang einer Route kann die Routenwahl im Radverkehr wesentlich beeinflussen. Dies hängt bspw. mit den physischen Gegebenheiten (z.B. Vegetation) und dem Erscheinungsbild insgesamt (Szenerie) zusammen, die die Wahrnehmung des Umfelds der Radfahrenden beeinflussen (siehe Kapitel 3).

Flächen, sowohl öffentliche als auch private, können prinzipiell unterschiedlich genutzt werden. Die Nutzungsarten (z.B. landwirtschaftliche Flächen, Waldflächen oder Siedlungsflächen) können beliebig kleinteilig in weitere Kategorien untergliedert sein (z.B. Unterscheidung von Siedlungsflächen in Flächen mit Wohn- oder gewerblicher Nutzung) (UBA-c 2020). Um die Flächennutzung abbilden und in die Analysen einfließen zu lassen, wurden Daten der Erweiterten Blockkarte (EBK) der Landeshauptstadt Dresden genutzt. Es handelt sich dabei um Flächennutzungsdaten, die das gesamte Stadtgebiet umfassen und den Flächen auf Blockebene unterschiedliche Nutzungsarten zuweisen (LH-Dresden-h 2020). Die Daten sind frei zugänglich und können über das kommunale Datenportal der Stadt heruntergeladen werden bzw. direkt in Geographische Informationssysteme (z.B. in QGIS) eingebunden und genutzt werden.

Die Daten zur Flächennutzung sind sehr detailliert – es existieren knapp 50 unterschiedliche Nutzungsarten. Da die sehr feinteilige Untergliederung für eine Analyse unge-

eignet ist (es würden sich allein für die Flächennutzung sehr viele unterschiedliche Variablen ergeben), wurden die Daten zu fünf Flächennutzungsklassen aggregiert. Sie lauten wie folgt:

- Wohnflächen
- Grünflächen (inkl. Wasser- und landwirtschaftliche Flächen)
- Gewerbe (inkl. öffentliche Gebäude) und Industrie
- Mischbebauung
- Sonstige

Ein detaillierter Überblick über die Flächennutzungsklassen der EBK und die Zuordnung zu den aggregierten Flächennutzungsklassen ist in Anhang 4 zu finden. Die Flächennutzungsdaten wurden anschließend mit den Kanten des Netzmodells verknüpft. Die Zuweisung der Flächennutzung erfolgte via Parallelverschiebung der Kanten in die genutzten Flächen, sodass für jede Netzkante Informationen zur Nutzungsart der straßenbegleitenden Flächen vorliegen. Bei mehreren unterschiedlichen Nutzungsarten wurde der prozentuale Anteil je Nutzungsart je Kante bestimmt. Auf die Nutzung der aufbereiteten Daten zur Berechnung der Eigenschaften der Routen/-alternativen wird in Kapitel 4.2.6 eingegangen.

**o) Alter und Geschlecht der Radfahrenden**

Die Literaturrecherche hat aufgezeigt, dass auch die Personencharakteristika (z.B. Alter und Geschlecht) einen Einfluss auf die Routenwahl haben können (siehe Kapitel 3). Um den Einfluss personenspezifischer Einflussvariablen auf die Routenwahl zu analysieren, wird auf die anonymisierten Zusatzdaten der Radfahrenden aus der Erhebung zurückgegriffen. Die Teilnehmenden des STADTRADELN mussten bei der Registrierung ihr Alter (in Jahren) und Geschlecht (männlich, weiblich, keine Angabe) angeben (siehe Kapitel 4.2.1). Diese Informationen wurden in einer separaten Datentabelle gespeichert. Über eine anonyme Device-ID konnte über das Gerät der Radfahrenden, das für die Aufzeichnung einer Strecke genutzt wurde, auf die Nutzer*innen geschlossen werden.

Im Ergebnis sind für jede Route und Routenalternative Informationen zu den Personencharakteristika (Alter und Geschlecht) der Radfahrenden vorhanden. Auf die Nutzung der aufbereiteten Daten zur Berechnung der Eigenschaften der Routen/-alternativen wird in Kapitel 4.2.6 eingegangen.

Am Ende der Sekundärdatenaufbereitung stehen umfangreiche Daten zur Verfügung, die entweder mit dem Netzmodell (siehe Kapitel 4.2.3) oder den Radfahrer*innen ver-

knüpft sind. Diese Verknüpfungen erlauben es in weiteren Schritten, die Routen und Routenalternativen mit Information anzureichern (siehe Kapitel 4.2.6), sodass für jede Route und ihre Alternativen spezifische Charakteristika berechnet werden können.

### 4.2.3 Netzmodell

Als Grundlage des Netzmodells wurde auf frei verfügbare Daten aus dem OpenStreetMap-Projekt (OSM) zurückgegriffen. Ursache für die Nutzung dieser Datengrundlage ist, dass dieses Netz für das Untersuchungsgebiet sehr umfangreiche Daten zu Netzkanten und -knoten bietet. Zudem spielte die Korrektheit der im OSM-Netz hinterlegten Attribute der Netzelemente keine Rolle, weil die für die Analyse notwendigen Attribute separat erhoben bzw. aufbereitet (siehe Kapitel 4.2.2) und den Netzelementen neu zugewiesen wurden.

Die Netzdaten, bestehend aus Knoten und Kanten, wurden über das Datenportal „Geofabrik“ bezogen (Geofabrik 2018). Es wurde zunächst ein Netz für das Gebiet des Bundeslandes Sachsen heruntergeladen und anschließend eine Teilregion, die über die Stadtgrenzen Dresdens hinausgeht, extrahiert. Der Zuschnitt der Teilregion erfolgte anhand der räumlichen Ausdehnung aller Radfahrten, die in dem GPS-Datensatz für die Stadt Dresden vorlagen.

Das resultierende Netzmodell weist eine Nord-Süd-Ausdehnung von ca. 62 km sowie eine Ost-West-Ausdehnung von ca. 48 km auf. Die Gesamtlänge beträgt rund 20.376 km. Es umfasst insgesamt 198.153 Knoten und 255.529 Kanten, die alle über einen eindeutigen Identifikator (ID) verfügen. Über diese IDs kann später ein Bezug zwischen den Kanten und Knoten sowie den Routen und Routenalternativen hergestellt werden, um die Routeneigenschaften zu berechnen (Attribuierung; siehe Kapitel 4.2.6).

An den Netzkanten wurden die in Kapitel 4.2.2 beschriebene Attribute hinterlegt. Damit liegen für den Raum Dresden für insgesamt 350 km Strecke sowie für 150 Knotenpunkte Informationen zu den in Kapitel 4.2.2 beschriebenen Attributen vor. Da aufgrund des hohen Aufwands einer Vollerhebung nicht für alle Strecken und Knoten des Netzmodells Daten erhoben und aufbereitet werden konnten (der Fokus wurde auf das Hauptverkehrsnetz gelegt) existieren im Netzmodell nicht für alle Kanten und Knoten Informationen zu den Eigenschaften. Insgesamt liegen zu rund 18,7 % aller im Netzmodell vorhanden Streckenabschnitte Informationen vor. Dieser Anteil wirkt zunächst gering, muss jedoch in Relation zum gesamten Netz gesetzt werden. Abbildung 21 zeigt den Ausschnitt des beschriebenen Gesamtnetzes (rechts) und stellt es den Netzelementen gegenüber, für die Daten der benannten Attribute in Dresden vorliegen (links; in blau). Es wird deutlich, dass für einen Großteil des städtischen Netzes Informationen vorliegen.

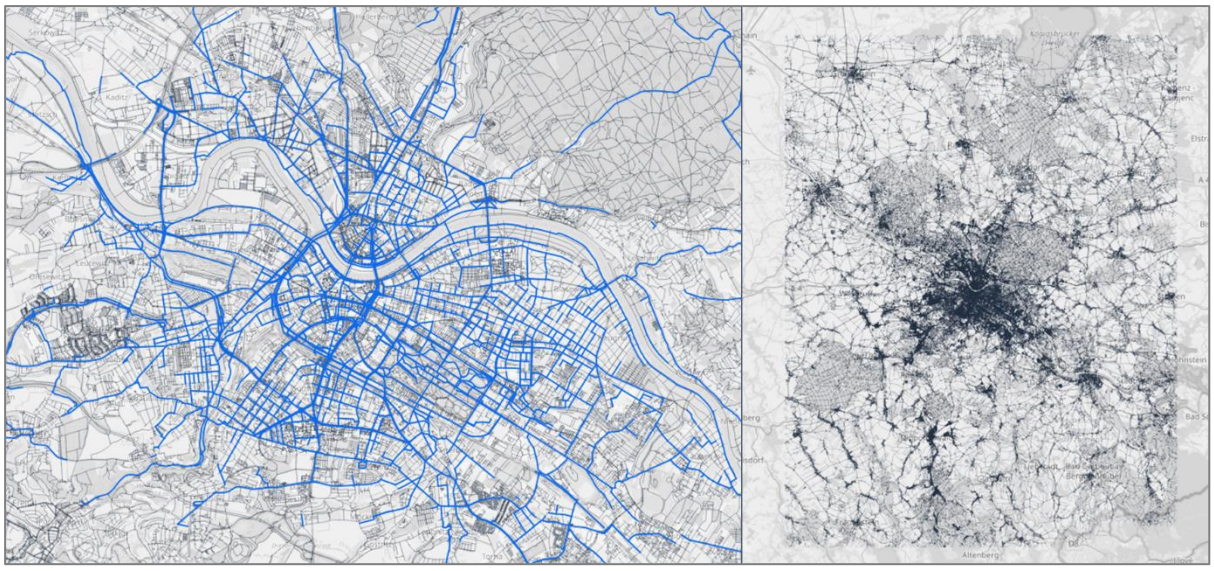

Abbildung 21: Darstellung des Netzmodells für den Dresdner Raum

Inwiefern sich fehlende Daten auf die Routeneigenschaften (Anteile ohne Informationen) auswirkt, wird in weiteren Schritten der Arbeit evaluiert. Das Netzmodell wurde für die folgenden Schritte des Map Matching (siehe Kapitel 4.2.4), das Erzeugen der Routenalternativen (siehe Kapitel 4.2.5) sowie die Attribuierung der Routen und Routenalternativen (siehe Kapitel 4.2.6) genutzt.

### 4.2.4 Map Matching

Für die Analyse der Routenwahl müssen die aufgezeichneten und aufbereiteten Routendaten mit Eigenschaften versehen werden, die in dem Netzmodell hinterlegt wurden. Nur durch das Übertragen der Eigenschaften der Netzelemente auf die Routen können für die einzelnen Routen und Alternativen auch routenspezifische Eigenschaften berechnet werden.

Die aufgezeichneten GPS-Punkte liegen bedingt durch Messungenauigkeiten (siehe Kapitel 2.3.1) jedoch nie exakt auf einem Element (Kante) im Netzmodell. Abbildung 22 verdeutlicht die Problematik. Die eindeutige Zuordnung eines jeden Punktes zu einer Kante ist daher nicht möglich. Visuell ließen sich die Punkte zwar leicht einer Kante zuordnen. Da bei der Vielzahl der Routen eine manuelle Zuordnung jedoch unverhältnismäßig viel Zeit in Anspruch nehmen würde bzw. zeitlich nicht umsetzbar wäre, muss eine automatisierte Zuordnung der Punkte zu den Netzelementen im Netzmodell erfolgen. Dieser Vorgang wird über ein sog. Map Matching automatisiert durchgeführt.

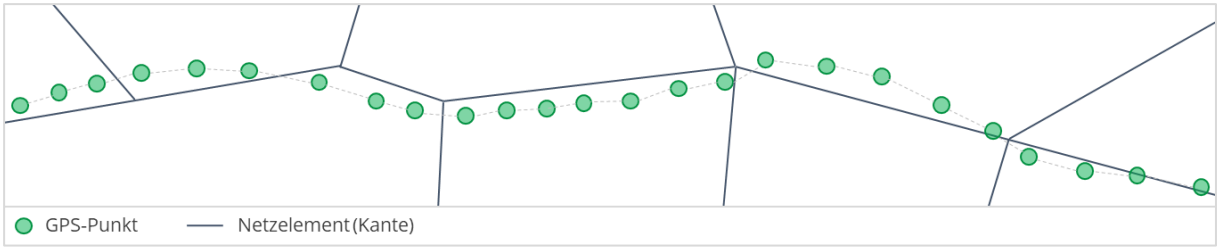


Abbildung 22: Ungenaue Lage von GPS-Punkten bedingt durch Messungenauigkeiten

Es existieren unterschiedliche Verfahren für das Map Matching. Relativ einfache Verfahren führen bspw. ein *point-to-curve matching* von GPS-Punkten durch und ordnen Punkte der räumlich nahegelegensten Kante zu (= minimale Luftliniendistanz). Es existieren jedoch auch komplexere Verfahren, die entsprechend bessere Ergebnisse liefern (Bierlaire, Chen und Newman 2013).

Für das Map Matching der Daten der vorliegenden Arbeit wird auf Graphhopper (eine Softwarebibliothek für geostatistische Analysen) zurückgegriffen. Graphhopper hat den Vorteil, dass die OSM-Daten des Netzmodells (siehe Kapitel 4.2.3) nativ unterstützt werden. Die Bibliothek kann damit zu einem späteren Zeitpunkt auch für das Generieren der Routenalternativen genutzt werden.

Graphhopper führt kein konventionelles Map Matching, wie bspw. das klassische und häufig genutzte p*oint-to-curve matching,* durch (White, Bernstein und Kornhauser 2000). Der Algorithmus bedient sich unterschiedlicher Verfahren für das Matching und nutzt dazu ein statistisches Verfahren nach Newson und Krumm 2009. Es besteht im Kern aus unterschiedlichen und miteinander verknüpften Algorithmen und Modellen (Dijkstra-Routing-Algorithmus, Hidden Markov Model, Viterbi-Algorithmus), die aus Gründen des Umfangs an dieser Stelle nicht erläutert werden. Detaillierte Informationen können (Newson und Krumm 2009) entnommen werden. Wichtig ist an dieser Stelle vor allem die grundlegende Funktionsweise zu verstehen.

Für das Map Machting wird zunächst die Punktdichte eines GPS-Track reduziert (nur ein Punkt alle 10 m), was die Performanz des Verfahrens erhöht. Dies ist bei der vorliegenden Datenmenge angebracht, weil die Berechnungszeitdauer sonst überaus hoch ausfallen würde. Abbildung 23 verdeutlicht das Ergebnis ggü. dem Original-Track (vgl. Abbildung 22).

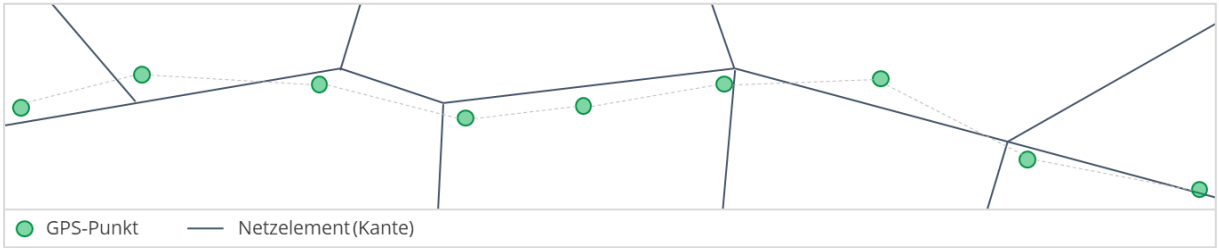


Abbildung 23: Reduzierter GPS-Track

In einem nächsten Schritt erfolgt die Suche nach sog. Knotenpunktkandidaten. Dabei wird ein Suchradius – eine Art Puffer – um die GPS-Punkte konstruiert und nur die Knoten des Angebotsnetzes ausgewählt, die sich innerhalb der erzeugten Puffer befinden (siehe Abbildung 24). Der Suchradius beträgt grundsätzlich 25 m, kann aber individuell angepasst werden. Für die vorliegende Arbeit wurde zudem die Genauigkeit (accuracy) der jeweiligen GPS-Punkte einbezogen und der Suchradius entsprechend erweitert (bei geringer Genauigkeit) oder verringert (bei hoher Genauigkeit).

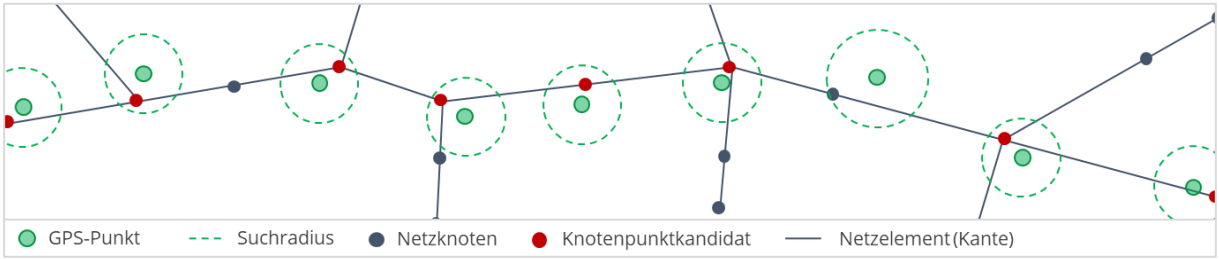


Abbildung 24: Suche von Knotenpunktkandidaten im Netz

Im darauffolgenden Schritt werden sog. Übergangswahrscheinlichkeiten zwischen den Punkten berechnet (Hidden-Markov-Model). In diesem Schritt findet auch das Routing Anwendung. Anschließend werden mittels Viterbi-Algorithmus über alle Punkte hinweg die Knotenpunktkandidaten ermittelt, für die die Übergangswahrscheinlichkeiten am höchsten sind. Aus diesen Knotenpunktkandidaten wird schlussendlich die genutzte Route über die Netzelemente rekonstruiert (siehe Abbildung 25). Detaillierte Informationen zur Funktionsweise des Map Matchings mittels Graphhopper können (Graphhopper-b 2020) entnommen werden.

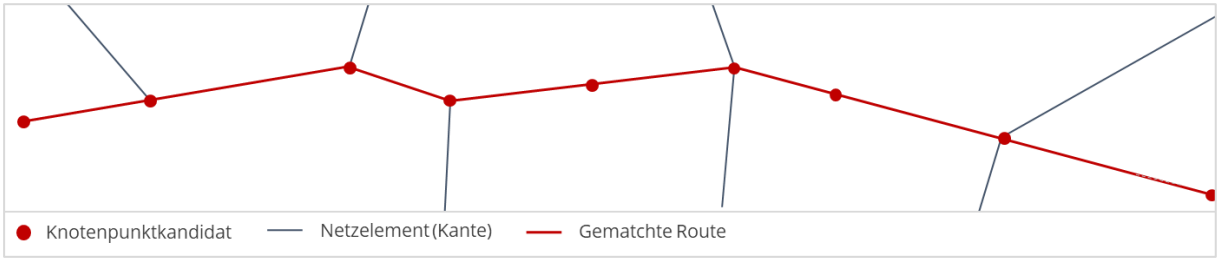


Abbildung 25: Ergebnis des Map Matching – die gematchte Route im Netz

Da für das Map Matching kein einfaches geometrisches Verfahren genutzt wurde, sondern zwischen den Punkten geroutet wird, kam es im Rahmen der Datenaufbereitung teils zu Abweichungen zwischen dem GPS-Track und der gematchten Route. Grund dafür können zum einen Ungenauigkeiten des GPS-Signals bei der Aufzeichnung oder fehlende Freigaben der Netzkanten (zur Befahrung mit dem Fahrrad) sein. Daraus resultierten teils Umwege der gematchten Route gegenüber dem GPS-Track und fehlerhafte Zuweisungen von Netzelementen, die im Folgenden die Routeneigenschaften verzerren und zu fehlerhaften Analyseergebnissen führen würden.

Um eine möglichst hohe Qualität der Ergebnisse des Map Matchings zu erreichen, wurde jeweils die räumliche Lage der GPS-Tracks und der gematchten Routen miteinander verglichen. Dazu wurde zunächst geprüft, ob die jeweils gematchte Route innerhalb des 15 m-Puffers des GPS-Tracks liegt. Anschließend wurden nur jene Routen genutzt, die mindestens zu 95 % innerhalb des Puffers lagen.

Ergebnis des Map Matching ist, dass für jeden GPS-Punkt einer Route Informationen zu den genutzten Netzelementen (Kanten) zur Verfügung stehen. Damit können für alle aufgezeichneten Tracks die im Verlauf der Route genutzten Netzelemente bestimmt werden. Diese Verknüpfung ermöglicht es in einem späteren Schritt, aus den im Netzmodell hinterlegten Eigenschaften der Netzelemente die Eigenschaften einer Route zu berechnen (siehe Kapitel 4.2.6).

### 4.2.5 Erzeugung von Alternativrouten

Um die Zusammenhänge der Routenwahl analysieren zu können, müssen Routenalternativen erzeugt werden, die jeder gewählten Route als nicht gewählte Alternative gegenübergestellt werden. Dabei existieren bestimmte Kriterien, die berücksichtigt werden und erfüllt sein müssen:

1. Die Start- und Endpunkte der Alternativen müssen identisch mit den Start- und Endpunkten der gewählten Route sein.
2. Die Wegelängen der Alternativen sollten in einem realistischen Verhältnis zur Länge der tatsächlich gefahrenen Route stehen (vgl. dazu Broach, Gliebe und Dill 2009). Praktisch bedeutet das, dass die Länge der Alternativen im Verhältnis zum kürzesten Weg nicht den Faktor 2 übersteigen sollten. Typische Umwege-Faktoren liegen im Radverkehr, vor allem in Abhängigkeit der Netzdichte, in der Regel bei 1,2-1,5.
3. Die erzeugten Routenalternativen sollten sich zueinander und zum gefahrenen Weg möglichst unterscheiden. Der Überlappungsgrad zwischen den Alternativen und der Route sollte möglichst gering sein bzw. im besten Fall gegen Null streben. Andernfalls würde es sich sonst um Varianten einer Route, aber nicht um echte Alternativen handeln (vgl. dazu Kapitel 2.2.4).
4. Die Nutzung von nahe beieinanderliegender (z.B. paralleler) Kanten sollte vermieden werden, weil vor allem in dichten Netzen die Routenalternativen sonst den gleichen Streckenverlauf haben könnten, obwohl sie unterschiedliche Netzkanten nutzen. Die Einhaltung von Kriterium zwei und drei wäre dadurch nicht gewährleistet.

5. Die Anzahl der Alternativen pro Route sollte realistisch sein. Durchgeführte Erhebungen weisen darauf hin, dass Radfahrende auf häufig zurückgelegten Alltagswegen durchschnittlich zwei bis drei Alternativen besitzen, die sie für eine Nutzung tatsächlich berücksichtigen (Friedrich 2019). Die Gesamtanzahl der erzeugten Routenalternativen sollte daher die Anzahl von zwei nicht überschreiten.

Alternativrouten können mit Hilfe unterschiedlicher Verfahren erzeugt werden (siehe Kapitel 2.2.4). Basierend auf dem in Kapitel 2.2.4 beschriebenen Best-Weg-Verfahren wurde ein Verfahren zur Erzeugung von Routenalternativen entwickelt, dass die oben genannten Kriterien einhält.

Der entwickelte Ansatz basiert prinzipiell auf einem Kürzeste-Wege-Routing, bezieht jedoch die gewählte Route sowie die, wenn vorhanden, bereits erzeugten Routenalternativen bei der Erzeugung weiterer Routenalterativen ein, indem er den Aufwand auf den bereits befahrenen Netzkanten erhöht. In Ansätzen wurde das Vorgehen bei (Chen, Bell und Bogenberger 2007) beschrieben und durch (Bader, et al. 2011) erweitert, die fortan vom sog. *Penalty Tube* Ansatz sprechen. Algorithmisch lässt sich der Ansatz wie folgt beschreiben:

1. Als Aufwand, der für das Best-Weg-Verfahren (Kürzeste-Wege-Routing) genutzt wird, wird die Länge einer Netzkante festgelegt.
2. Um die gewählte Route wird ein Puffer mit dem Radius *r* (in Metern) erzeugt und zu einer Liste, der sogenannten *penalty tubes list*, hinzugefügt.
3. Befindet sich eine zu berücksichtigende Netzkante innerhalb des Puffers aus der *penalty tubes list*, wird der Aufwand (hier: Länge) mit dem Aufwandsfaktor *pf* (*penalty factor*) skaliert. Der Aufwand aller Netzkanten innerhalb des Puffers wird mit diesem Faktor erhöht. Der Faktor *pf* ist festzulegen.
4. Anschließend wird ein Best-Weg-Verfahren (hier: Dijkstra-Routing) zwischen Start- und Endpunkt des gefahrenen Weges ausgeführt. Der Routing-Algorithmus berücksichtig bei dem Finden einer Route den Aufwand (hier: Länge einer Kante) und sucht daher den „aufwandsminimalsten“ Weg zwischen Quell- und Zielpunkt.
5. Die erzeugte Routenalternative wird dem Set möglicher Alternativrouten hinzugefügt.
6. Um die erzeugte Routenalternative wird anschließend ein Puffer mit dem Radius *r* gelegt und zu der *penalty tube list* hinzugefügt.

7. Die Schritte drei bis fünf werden so lange wiederholt, bis *k* mögliche Alternativrouten erzeugt wurden.

Der Radius *d* der zu erzeugenden *Tubes*, der Aufwandsfaktor *pf* und die Anzahl möglicher Alternativrouten *k* ist bei dem Ansatz frei wählbar. Abbildung 26 verdeutlicht das Ergebnis des Vorgehens schematisch an einem Beispiel. Sie zeigt die gewählte Route (blau) sowie zwei mit dem beschriebenen Verfahren erzeugte Routenalternativen (grün, braun).

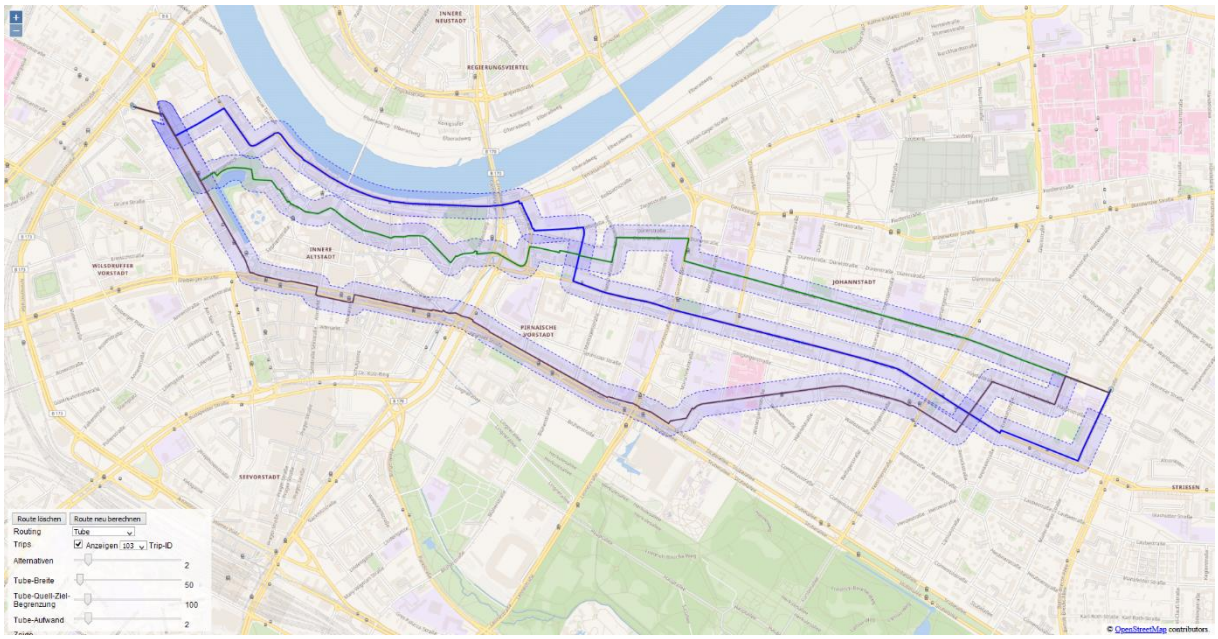


Abbildung 26: Gewählte Route (blau) und erzeugte Routenalterativen (grün, braun) (Darstellung: Lindemann)

Die Wahl eines Streckenabschnitts innerhalb des Routings ist, wie beschrieben, durch die vorherigen Routen (Aufwanderhöhung durch den pf) mitbestimmt. Am Start- bzw. Zielpunkt sollte der Effekt jedoch weniger stark ausgeprägt sein, damit Routenalternativen z.B. nicht entgegen der eigentlichen Fahrtrichtung starten. Daher wurde der Ansatz so angepasst, dass es möglich ist, den Puffer erst ab einer bestimmten Distanz vom Start- bzw. Zielpunkt zu erzeugen. Dazu wurde das Verfahren um die sog. Verkürzungslänge O erweitert. Ein Beispiel für die Nutzung eines verkürzten Puffers ist in Abbildung 27 dargestellt. Dabei wurde eine Verkürzung von 150 Metern gewählt.

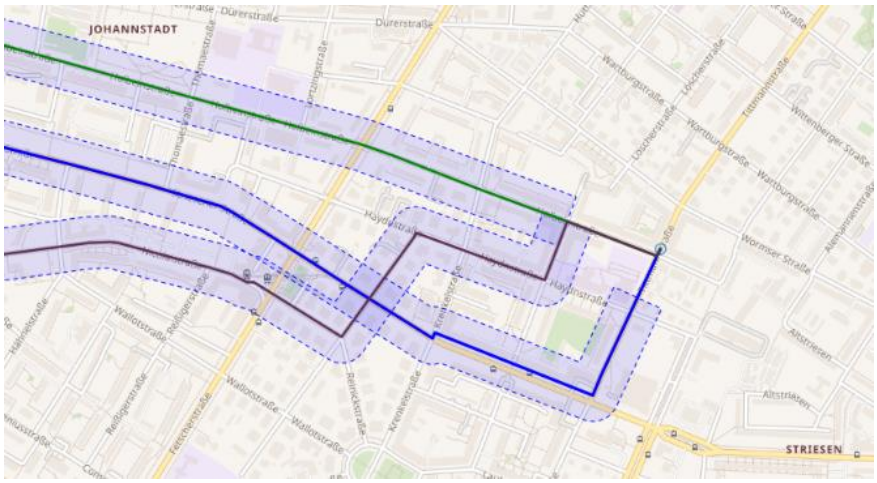


Abbildung 27: Pufferbildung ab Verkürzungslänge O (Darstellung: Lindemann)

Eine erste Analyse der erzeugten Alternativrouten zeigte, dass sich diese deutlich voneinander und von der gewählten Route unterscheiden. Zudem wirken die erzeugten Alternativen „natürlich“ bzw. „intuitiv“ und lassen sich leicht nachvollziehen bzw. interpretieren.

Ein entscheidender Aspekt des Ansatzes besteht darin, dass er grundlegend geometrisch ist: Das bedeutet, dass er unabhängig von thematischen Attributen operieren kann. Das macht ihn sehr attraktiv und vor allem nutzbar, auch wenn bspw. für das städtische Gesamtnetz keine Attribute erhoben wurden oder noch nicht alle wesentlichen Attribute vorliegen.

In Abhängigkeit der Charakteristika der tatsächlich gewählten Route wird mit dem gewählten Ansatz eine Routenalternative erzeugt, die dem kürzesten Weg gleichkommt – falls die gewählte Route nicht bereits dem kürzesten Weg entspricht. Zudem wird eine zweite, jedoch deutlich längere, Routenalternative erzeugt. Alle Routen des Alternativen-Sets unterscheiden sich dabei räumlich stark von der gefahrenen Route, sodass „echte“ Alternativen (keine Varianten) zur gewählten Route erzeugt werden (vgl. Abbildung 26). Der Ansatz verspricht aufgrund seiner Robustheit, relativ einfachen Umsetzbarkeit sowie seiner genauen Steuerbarkeit konsistente und aussagekräftige Ergebnisse für den benötigten Anwendungsfall.

Der Ansatz greift, so wie das Map Matching auch, auf Graphhopper zurück. Dabei werden der von der Softwarebibliothek erzeugte Verkehrsgraph sowie die grundlegend implementierte Routingfunktionalität von Graphhopper genutzt. Der Ansatz ist durch die folgenden vier Parameter steuerbar:

- Tube-Durchmesser *d*
- Aufwandsfaktor *pf*
- Verkürzungslänge *O*
- die Anzahl der zu erzeugenden Routen *k*

Um eine Konfiguration zu finden, mit der die Zielkriterien eins bis fünf (siehe oben) möglichst erfüllt werden und mit denen für jede gewählte Route plausible Alternativrouten erzeugt werden können, wurde ein Tool implementiert, mit dessen Hilfe die Methode getestet wurde. Dafür wurde die Anwendung an einen HTTP-Server überführt und eine Weboberfläche erstellt, die es ermöglicht, tatsächlich gefahrene Wege mit einzubeziehen, Routenalternativen zu erzeugen und anzeigen zu lassen sowie die beschriebenen Parameter anzupassen (siehe Abbildung 26). Mit dem Tool wurde für einen Testdatensatz eine hinreichend gute Konfiguration gefunden, mit der schließlich die Alternativrouten für den Routen-Datensatz erzeugt werden. Die gefundenen Parameter sind:

- d = 100 m
- pf = 2
- O = 100
- k = 2

Dass die Konfiguration für die Erzeugung der Routenalternativen geeignet ist und die Zielkriterien eingehalten werden, zeigt die Auswertung der Überlappungsgrade der einzelnen Routen mit den Routenalternativen. Aus der Betrachtung der Verteilung der Überlappungsgrade über alle Routen und ihre jeweiligen Alternativen wird deutlich, dass der Großteil der Routen nur sehr geringe Anteile mit gemeinsamen Routenabschnitten (Kanten) besitzt. Rund 25 % aller Routen besitzen keine gemeinsamen Streckenabschnitte mit ihren Alternativen. Etwa 82 % aller Routen besitzen eine Überlappung mit ihren Alternativen von weniger als 10 % und im Durchschnitt machen die gemeinsamen Streckenabschnitte nur rund 2 % (Median) bzw. 7 % (Mittelwert) aus. Bei einer durchschnittlichen Routenlänge von 3,8 km (siehe Kapitel 5.1) würde die Länge der gemeinsamen Routenabschnitte in diesem Fall nur rund 80 m bzw. 282 m betragen. Dieser Wert wird vor allem auf gemeinsame Streckenabschnitte zu Beginn und am Ende einer Route zurückgeführt, bei denen die Nutzung gemeinsamer Streckenabschnitte kaum zu vermeiden ist.

### 4.2.6 Attribuierung der Routen/-alternativen

Die Attribuierung verknüpft die netzseitig vorliegenden Sekundärdaten (siehe Kapitel 4.2.2) mit den Routen und den Routenalternativen. Da die erhobenen Sekundärdaten einheitlich sowie kanten- bzw. knotenfein im Netzmodell hinterlegt wurden, ist eine Attribuierung der Routen und Alternativen algorithmisch relativ problemlos möglich.

Um die Eigenschaften einer Route/Alternative zu berechnen, werden in einem ersten Schritt die IDs der genutzten Kanten und Knoten je Route/Alternative abgefragt. Die benötigten Informationen für die Routen kommen aus dem Map Matching (siehe Kapitel

4.2.4). Für die Alternativen kann auf die Informationen zurückgegriffen werden, die bei der Erzeugung der Alternativrouten (siehe Kapitel 4.2.5) entstehen. In beiden Fällen sind die IDs der genutzten Kanten und Knoten gespeichert.

Für die Berechnung der Routeneigenschaften wird in einem nächsten Schritt über die IDs der Kanten auf die Merkmalsausprägungen der Variablen (Attribute) zugegriffen. Die Eigenschaften werden für den Großteil der Attribute in einem relativen Maß bestimmt, damit sie vergleichbar sind. Die Attribuierung der Routen erfolgt für die beschriebenen Einflussfaktoren wie folgt:

**a) Distanz & Reisezeit**

Die Fahrtweiten $d_R$ und Reisezeiten $t_R$ wurden bereits im Rahmen des Map Matching und der Erzeugung der Routenalternativen bestimmt, sodass direkt auf die Werte für jede Route bzw. Routenalternative zurückgegriffen werden kann.

**b) Längsneigung**

Die Längsneigung liegt für jede Kante im Netzmodell vor (siehe Kapitel 4.2.2). In einem ersten Schritt wird die maximale Längsneigung $LN_{max}$ aller entlang der Route $R$ genutzten Kanten $k$ ermittelt und als Eigenschaft hinterlegt. Die Berechnung erfolgt nach

$$LN_{max;R} = MAX\,\{LN_{k;R}\} \tag{15}$$

In einem weiteren Schritt wird die durchschnittliche Längsneigung entlang einer Route bestimmt. Sie errechnet sich aus dem arithmetischen Mittel der Längsneigung $LN$ aller genutzten Kanten $k$ entlang einer Route $R$ nach

$$LN_{avg;R} = \frac{1}{n_k}\sum_{k=1}^{n} LN \tag{16}$$

Darüber hinaus werden die Netzkanten entsprechend ihrer Steigung unterschiedlichen Längsneigungsklassen $LNK$ zugeordnet. Die Klassen sind:

1. Längsneigung < 2 %
2. Längsneigung von 2-4 %
3. Längsneigung > 4 %
4. Längsneigung < 0 % (Gefälle)

Mithilfe dieser Zuordnung kann bestimmt werden, wie viel Prozent einer Route einer entsprechenden Klasse angehören. Der relative Anteil einer Längsneigungsklasse $h_{LNK}$ einer Route $R$ berechnet sich aus dem Quotienten der Streckenlänge mit einer Steigungsklasse $LNK_i$ und der Gesamtlänge einer Route. Die Berechnung erfolgt nach

$$h_{LNK} = \frac{\sum s_{LNK;k}}{\sum_{k=1}^{n} s_{LNK;k}} \tag{17}$$

mit $h_{LNK}$ als prozentualer Anteil einer Längsneigungsklasse einer Route *R* und $s_{LNK;k}$ als Länge der einzelnen Netzkanten *k* einer Längsneigungsklasse *LNK*.

**c) Radverkehrsführungsform**

Die Radverkehrsführungsformen (siehe Kapitel 4.2.2) werden ebenfalls anteilig an der Streckenlänge für jede Route/Alternative bestimmt und für die Gesamtroute angegeben. Die Berechnung erfolgt entsprechend nach

$$h_{RVF;R} = \frac{\sum s_{RVF;k}}{\sum_{k=1}^{n} s_{RVF;k}} \tag{18}$$

mit $h_{RVF;R}$ als prozentualer Anteil einer Radverkehrsführungsform *RVF* entlang einer Route *R* und $s_{RVF;k}$ als Länge der einzelnen Netzkanten *k* mit der Führungsform *RVF*.

**d) Breite der Radverkehrsführung**

Da die Breite der Radverkehrsführung als metrischer Wert für jede Netzkante vorliegt und die Maße nicht immer einheitlich sind, können unendlich viele unterschiedliche Werte für die Breite entlang einer Route vorliegen. Daher wurden die Werte in einem ersten Schritt definierten Klassen zugeordnet. Diese Klassen zur Breite *b* sind an die Regelmaße der ERA (FGSV 2010) angelehnt. Sie sind wie folgt definiert:

1. b < 1,5 m
2. 1,5 m ≤ b ≤ 2 m
3. b > 2 m
4. keine Angabe

Die Breite der Radverkehrsführung wird ebenfalls anteilig an der Gesamtlänge einer Route/Alternative bestimmt. Die Berechnung erfolgt nach

$$h_{B;R} = \frac{\sum s_{B;k}}{\sum_{k=1}^{n} s_{B;k}} \tag{19}$$

mit $h_{B;R}$ als prozentualer Anteil einer Breiten-Klasse *B* entlang einer Route *R* und $s_{B;k}$ als Länge der einzelnen Kante *k* mit der Breitenklasse *B*.

### e) Oberflächenbeschaffenheit

Die Oberflächenbeschaffenheit (siehe Kapitel 4.2.2) wird ebenfalls anteilig je Route und Alternative bestimmt. Die Berechnung erfolgt analog zu den Längsneigungsklassen aus dem Quotienten der Streckenlängen einer Oberflächenkategorie (siehe Kapitel 4.2.2) und der Gesamtlänge einer Route nach

$$h_{OF;R} = \frac{\sum s_{OF;k}}{\sum_{k=1}^{n} s_{OF;k}} \tag{20}$$

mit $h_{OF;R}$ als prozentualer Anteil einer Oberflächenkategorie *OF* einer Route *R* und $s_{OF;k}$ als Länge der einzelnen Netzkanten *k* einer Oberflächenkategorie *OF*.

### f) Radverkehrsstärken

Die Radverkehrsstärke ($DTV_{Rad}$) liegt als metrischer Wert für jede einzelne Netzkante vor. Aus diesen Informationen kann für jede Route und Alternative zunächst ein harmonisches Mittel der Radverkehrsstärken bestimmt werden (Gewichtung anhand der Länge der Netzkanten). Die Berechnung erfolgt nach

$$\bar{h}_{DTV_Rad;R} = \frac{\sum s_{DTV_Rad;k}}{\sum_{k=1}^{n} s_{DTV_Rad;k}} \tag{21}$$

mit $\bar{h}_{DTV_Rad;R}$ als mittlerer $DTV_{Rad}$ entlang einer Route *R* und $s_{DTV_Rad;k}$ als Länge der einzelnen Netzkanten *k* mit einem kantenspezifischen $DTV_{Rad}$.

Da die Werte eines mittleren $DTV_{Rad}$ entlang der Routen u.U. sehr ähnlich sein können und ein mittlerer $DTV_{Rad}$ damit wenig Aussagekraft für die Routenwahl besäße, wurden die kantenspezifischen Werte des $DTV_{Rad}$ für die Attribuierung zusätzlich verschiedenen Klassen zugeordnet. Sie können später einzeln ausgewiesen werden und in die Analyse einfließen. Diese Klassen wurden wie folgt definiert:

1. Durchschnittlicher $DTV_{Rad}$ entlang der Route
2. $DTV_{Rad} \leq 500$
3. $500 < DTV_{Rad} \leq 1.000$
4. $1.000 < DTV_{Rad} \leq 1.500$
5. $1.500 < DTV_{Rad} \leq 2.000$
6. $2.000 < DTV_{Rad} \leq 2.500$
7. $DTV_{Rad} > 2.500$
8. keine Angabe

Der $DTV_{Rad}$ der genannten Klassen wird ebenfalls anteilig an der Gesamtlänge einer Route/Alternative bestimmt. Die Berechnung erfolgt nach

$$h_{DTV_Rad_k;R} = \frac{\sum s_{DTV_Rad_k;i}}{\sum_{k=1}^{n} s_{DTV_Rad_k;i}} \tag{22}$$

mit $h_{DTV_Rad_KL;R}$ als prozentualer Anteil einer $DTV_{Rad}$-Klasse *KL* entlang einer Route *R* und $s_{DTV_Rad_KL;k}$ als Länge der einzelnen Netzkanten *k* einer $DTV_{Rad}$-Klasse *KL*. Im Ergebnis stehen für jede Route und deren Alternativen Informationen zum mittleren $DTV_{Rad}$ sowie zu den Anteilen der genannten DTV-Klassen bereit.

### g) Kraftfahrzeugverkehrsstärke

Die Kraftfahrzeugverkehrsstärke ($DTV_{Kfz}$) liegt ebenfalls als metrischer Wert für jede Netzkante vor. Da die Werte sehr unterschiedlich sein können und dadurch verschiedene Ausprägungen der Variable auftreten können, wurden die Werte ebenfalls Klassen zugeordnet. Diese Klassen sind wie folgt definiert:

1. Durchschnittlicher $DTV_{Kfz}$ entlang der Route
2. $DTV_{Kfz}$ < 5.000 Kfz/d
3. 5.000 ≤ $DTV_{Kfz}$ ≤ 10.000 Kfz/d
4. $DTV_{Kfz}$ > 10.000 Kfz/d
5. Keine Angabe

Der $DTV_{Kfz}$ wird ebenfalls anteilig an der Gesamtlänge einer Route/Alternative bestimmt. Die Berechnung erfolgt nach

$$h_{DTV_Kfz;R} = \frac{\sum s_{DTV_Kfz;k}}{\sum_{k=1}^{n} s_{DTV_Kfz;k}} \tag{23}$$

mit $h_{DTV_Kfz;R}$ als prozentualer Anteil einer DTV-Klasse *DTV* entlang einer Route *R* und $s_{DTV_Kfz;k}$ als Länge der einzelnen Kanten *k* einer DTV-Klasse $DTV_{Kfz}$.

### h) Anzahl Fahrstreifen

Die Anzahl der Fahrstreifen (siehe Kapitel 4.2.2) entlang einer Route wird ebenfalls anteilig an der Gesamtstreckenlänge einer jeden Route/Alternative bestimmt und anschließend für die Gesamtroute angegeben.

Um nicht zu viele Ausprägungen der Variable zu erhalten, wird die Anzahl der Fahrstreifen *FS* zunächst den folgenden vier Klassen zugeordnet:

1. FS = 1
2. FS = 2
3. FS > 2
4. Keine Angabe

Anschließend wird der Anteil dieser Klassen an der Gesamtstrecke einer Route/Alternative bestimmt. Die Berechnung erfolgt nach

$$h_{FS;R} = \frac{\sum s_{FS;k}}{\sum_{k=1}^{n} s_{FS;k}} \tag{24}$$

mit $h_{FS;R}$ als prozentualer Anteil einer Fahrstreifen-Klasse *FS* entlang einer Route *R* sowie $s_{FS;k}$ als Länge der einzelnen Netzkanten *k* mit der Fahrstreifen-Klasse *FS*.

### i) Zulässige Höchstgeschwindigkeit des MV

Für die maximal zulässige Höchstgeschwindigkeit liegen im Netzmodell bereits klassifizierte Werte vor (siehe Kapitel 4.2.2). Zur Attribuierung der Route/Alternativen wird auf die im Netzmodell hinterlegten Informationen zur zulässigen Höchstgeschwindigkeit je Kante zurückgegriffen. Die Geschwindigkeit wird ebenfalls anteilig an der Gesamtlänge einer Route/Alternative bestimmt. Die Berechnung erfolgt nach

$$h_{V;R} = \frac{\sum s_{V;k}}{\sum_{k=1}^{n} s_{V;k}} \tag{25}$$

mit $h_{V;R}$ als prozentualer Anteil einer Geschwindigkeits-Klasse *V* entlang einer Route *R* und $s_{V;k}$ als Länge der einzelnen Netzkanten *k* einer Geschwindigkeits-Klasse *V*.

### j) Ruhender Verkehr

Der ruhende Verkehr wird ebenfalls anteilig je Route/Alternative bestimmt. Im Netzmodell liegen bereits Kategorien (siehe Kapitel 4.2.2) je Kante vor, auf die für die Berechnung zurückgegriffen wird. Die Berechnung erfolgt nach

$$h_{RV;R} = \frac{\sum s_{RV;k}}{\sum_{k=1}^{n} s_{RV;k}} \tag{26}$$

mit $h_{RV;R}$ als prozentualer Anteil einer Kategorie *RV* des ruhenden Verkehrs entlang einer Route *R* und $s_{RV;k}$ als Länge der einzelnen Netzkanten *k* einer Kategorie *RV*.

### k) Sicherheitsraum

Der Sicherheitsraum wird ebenfalls anteilig an der Gesamtlänge einer Route bzw. Alternative bestimmt. Da die Werte für dieses Attribut ebenfalls nicht einheitlich sind, wurden die Breiten *b* des Sicherheitsraumes in einem ersten Schritt zu Klassen entsprechend den Empfehlungen der ERA (FGSV 2010) zugeordnet. Die Klassen lauten wie folgt:

1. b < 0,5 m
2. 0,5 m ≤ b ≤ 0,75 m
3. b > 0,75 m
4. keine Angabe

Die Breite des Sicherheitsraumes wurde anschließend anteilig an der Gesamtlänge einer Route/Alternative bestimmt. Die Berechnung erfolgt nach

$$h_{SR;R} = \frac{\sum s_{SR;k}}{\sum_{k=1}^{n} s_{SR;k}} \tag{27}$$

mit $h_{SR;R}$ als prozentualer Anteil einer Klasse *SR* des Sicherheitsraumes entlang einer Route *R* und $s_{SR;k}$ als Länge der einzelnen Netzkanten *k* mit der Breitenklasse des Sicherheitsraumes *SR*.

### l) Sicherheit

Zur Attribuierung sicherheitsrelevanter Parameter wird auf die im Netzmodell hinterlegten Informationen zur Unfallanzahl sowie auf die Informationen zur Anzahl der Punkte subjektiver „Unsicherheit“ (kritische Situationen) je Kante und Knotenpunkt zurückgegriffen (siehe Kapitel 4.2.2). Dazu werden je Route und Routenalternative die Anzahl der Unfälle und die Anzahl der Punkte kritischer Situationen aufsummiert und ins Verhältnis zu der Gesamtstrecke einer Route/Alternative gesetzt. Die streckenbezogene Berechnung erfolgt nach

$$UH_R = \frac{\sum n_{U;R}}{\sum_{k=1}^{n} s_{k;R}} \tag{28}$$

mit $UH_R$ als Unfallhäufigkeit je Strecken-Kilometer (n/km) entlang einer Route *R sowie* $n_{U;R}$ als absolute Unfallanzahl und $s_{k;R}$ als Länge der einzelnen Netzkanten *k* entlang einer Route *R*. Die Berechnung kritischer Situation erfolgt analog nach

$$HKS_R = \frac{\sum n_{KS;R}}{\sum_{k=1}^{n} s_{k;R}} \tag{29}$$

mit $HKS_R$ als Häufigkeit kritischer Situationen je Strecken-Kilometer (n/km) entlang einer Route *R sowie* $n_{KS;R}$ als absolute Anzahl der Punkte kritischer Situationen und $s_{k;R}$ als Länge der einzelnen Kanten *k* entlang einer Route *R*.

**m) Knotenpunkte und deren Regelung**

Zur Attribuierung der Routen/Alterativen mit Informationen zu den Knotenpunkten und deren Regelung wird ebenfalls auf die im Netzmodell hinterlegten Informationen zurückgegriffen. Für alle Routen/Alternativen sind durch das Map Matching (siehe Kapitel 4.2.4) die genutzten Knotenpunkte und ihre Regelungsart bekannt (siehe Kapitel 4.2.2). Im Rahmen der Attribuierung wird die Gesamtanzahl der Knoten entlang einer Route/Alternative bestimmt. Zudem wird nach Art der Regelung unterschieden. Die Anzahl der Knotenpunkte werden je Kategorie aufsummiert und ins Verhältnis zur Gesamtstrecke einer Route/Alternative gesetzt. Die Berechnung erfolgt nach

$$KP_R = \frac{\sum n_{KP;R}}{\sum_{k=1}^{n} s_{k;R}} \tag{30}$$

mit $KP_R$ als Knotenpunktanzahl je Strecken-Kilometer und Regelungsart entlang einer Route *R sowie* $n_{KP;R}$ als absolute Anzahl der Knotenpunkte je Regelungsart und $s_{k;R}$ als Länge der einzelnen Netzkanten *k* entlang einer Route *R*. Die Regelungsarten können zudem aggregiert werden, sodass die Gesamtanzahl der Knotenpunkte entlang einer Route berechnet werden kann.

**n) Flächennutzung**

Für die Bestimmung der Flächennutzung wird auf die Flächennutzungsinformationen zu den einzelnen Kanten im Netzmodell zurückgegriffen. Es werden, ebenso wie bei den anderen Attributen, relative Anteile berechnet. Dazu werden die Streckenlängen der einzelnen Kanten *k* einer Flächennutzungs-Kategorie *FN* entlang einer Route *R* aufsummiert und ins Verhältnis zur Gesamtstreckenlänge einer Route gesetzt. Die Berechnung erfolgt nach

$$h_{FN;R} = \frac{\sum s_{FN;k}}{\sum_{k=1}^{n} s_{FN;k}} \tag{31}$$

mit $h_{FN;R}$ als prozentualer Anteil einer Kategorie *FN* entlang einer Route *R* sowie $s_{FN;k}$ als Länge der einzelnen Netzkanten *k* einer Flächennutzungs-Kategorie *FN*.

**o) Alter und Geschlecht der Radfahrenden**

Das Alter und Geschlecht der Radfahrenden wurden aus der PostgreSQL-Datenbank mit den Nutzerdaten entnommen und über die Trip-ID mit den Routen und ihren Alternativen verknüpft.

Zur Attribuierung der Routen und Routenalternativen wurde ein Python-Skript genutzt, das im Rahmen des Projekts „Sichere Routenwahl“ programmiert wurde. Am Ende der Attribuierung stehen für jede Route und ihre beiden Routenalternativen umfassende Informationen zur deren Eigenschaften zur Verfügung. Abbildung 28 fasst die beschriebenen Aufbereitungsschritte nach der Primärdatenaufbereitung noch einmal grafisch zusammen.

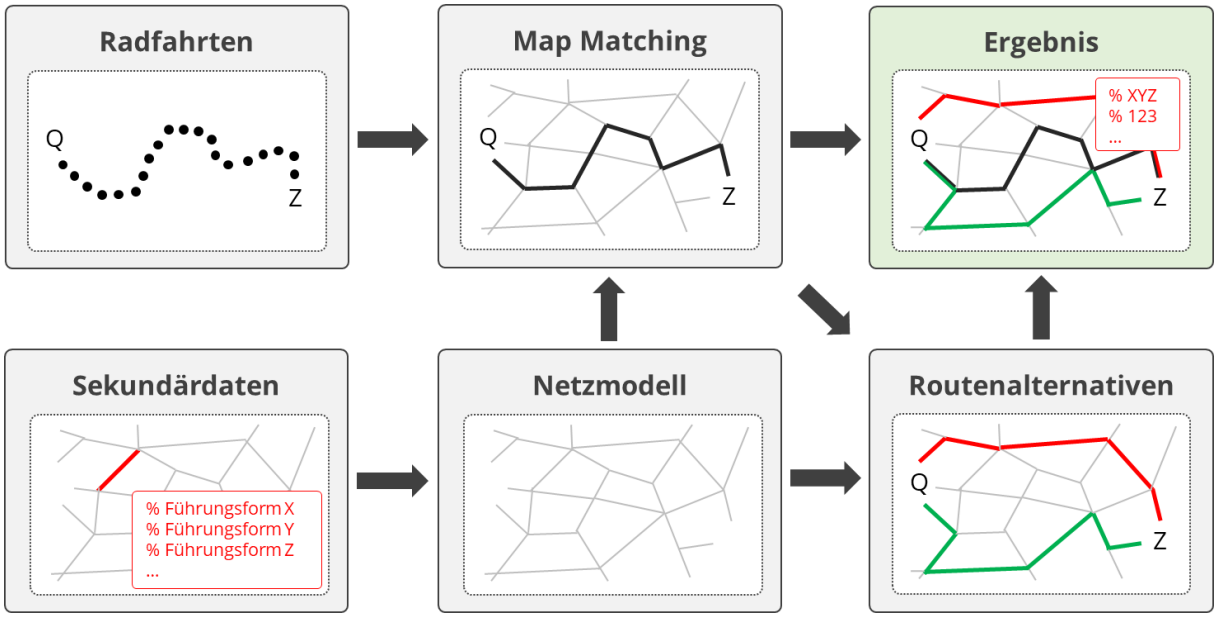


Abbildung 28: Überblick über die Datenverarbeitung ausgehend von den aufbereiteten Radfahrten

### 4.2.7 Zusammenfassung der Datenaufbereitung

Um die für die Analysen notwendigen Daten zu erzeugen, wurden die in den vorangegangenen Kapiteln beschriebenen Methoden angewendet. Da die Beschreibung der Methoden sehr umfangreich ist, soll der methodische Ablauf und das Ergebnis noch einmal kurz zusammengefasst werden.

Während der Aktion STADTRADELN 2019 wurden für das Untersuchungsgebiet (siehe Kapitel 4.1) Routen von Radfahrenden in Form von GPS-Tracks erhoben (siehe Kapitel 4.2.1.1). Da die aufgezeichneten und übermittelten Daten teilweise fehlerbehaftet waren, wurde eine umfangreiche Datenaufbereitung durchgeführt (siehe Kapitel 4.2.1.2), sodass

am Ende der Primärdatenaufbereitung aufbereitete Daten (GPS-Tracks) zu Radfahrten in Dresden vorlagen.

Um die Routen und ihre Alternativen charakterisieren zu können, wurden Sekundärdaten recherchiert, teils nacherhoben und aufbereitet (siehe Kapitel 4.2.2). Die aufbereiteten Informationen wurden anschließend mit einem Netzmodell (siehe Kapitel 4.2.3) verknüpft und als Attribute hinterlegt, sodass für die einzelnen Netzelemente (Kanten und Knoten) im Untersuchungsgebiet umfangreiche Informationen zu deren Eigenschaften vorliegen.

Auf Basis des beschriebenen Netzmodells sowie des gewählten Map Matching-Verfahrens konnten die gewählten Radrouten den einzelnen Elementen im Netz zugeordnet werden (siehe Kapitel 4.2.4). Das Netzmodell wurde ebenfalls dazu genutzt, Routenalternativen zu erzeugen (siehe Kapitel 4.2.5), die den gewählten Routen in der Analyse als nicht gewählte Alternativen gegenübergestellt werden.

In einem letzten Schritt wurden schließlich die Eigenschaften der Routen und Alternativen bestimmt (siehe Kapitel 4.2.6). Grundlage dafür waren die aufbereiteten und im Netzmodell hinterlegten Sekundärdaten.

Im Ergebnis stehen am Ende der Primär- und Sekundärdatenaufbereitung alle Informationen zur Verfügung, die für die Analysen notwendig sind: die Eigenschaften je gewählter Route sowie für die nicht gewählten Routenalternativen.

## 4.3 Routenwahlmodell

Mit Hilfe der aufbereiteten Routendaten kann nun der Einfluss unterschiedlicher Eigenschaften der Routen auf die Routenwahl der Radfahrenden analysiert werden. Dazu wird in der vorliegenden Arbeit ein logistisches Regressionsmodell genutzt. In den folgenden Abschnitten wird einerseits das genutzte Modell beschrieben. Darüber hinaus werden unterschiedliche Güte-Maße erläutert, die zur Bestimmung der Modell-Güte verwendet werden können.

### 4.3.1 Diskretes Wahlmodell

Die multiple logistische Regression ist eine etablierte Methode zur Analyse der Einflussfaktoren diskreter Entscheidungen. Das multiple Regressionsmodell wird in der Verkehrsforschung besonders aufgrund seiner einfachen Handhabung genutzt. Den vielfältigen Anwendungsmöglichkeiten und der vergleichsweise simplen mathematischen Formulierung steht für das vorliegende Thema jedoch mit der sog. *Independence of Irrelevant Alternatives* (kurz IAA) eine restriktive Annahme gegenüber (siehe Kapitel 2.2).

Statistisch betrachtet tendiert ein klassisches logistisches Regressionsmodell (z.B. bei der multinomialen logistischen Regression) dazu, eine hohe Wahrscheinlichkeit all jenen Routen zuzuweisen, die einen hohen Anteil gemeinsamer Routenabschnitte (Kanten im Netz) besitzen. Eine fehlende Berücksichtigung der IIA-Eigenschaft (siehe Kapitel 2.2.4) kann daher zu fehlerhaften bzw. verzerrten Analyseergebnissen und Modellen führen. Aus Verhaltensperspektive eines Radfahrenden betrachtet lässt sich zudem argumentieren, dass sich stark überschneidende Routen für Radfahrer*innen eher als zwei unterschiedliche Varianten einer Route betrachten lassen und nicht als zwei echte Alternativrouten.

Um das Problem von sich überlappenden Alternativen zu beheben, existieren prinzipiell drei Möglichkeiten:

1. Durch die Anwendung eines Korrekturfaktors kann der Nutzen von sich überlappenden Routenabschnitten angepasst werden.
2. Es können komplexe Modelle genutzt werden, die unempfindlich gegenüber korrelierten Fehler sind bzw. diese tolerieren, wie bspw. Multinomial-Probit-Modelle oder GEV-Modelle (Broach, Dill und Gliebe 2012)
3. Die Überlappungen der Alternativen müssen bei der Erzeugung von Alternativen vermieden werden.

Aus Gründen der Konsistenz und Einfachheit wurde für die vorliegende Arbeit Option drei gewählt (siehe Kapitel 4.2.5), wodurch das klassische multiple Regressionsmodell beibehalten und genutzt werden kann. Darüber hinaus kann das resultierende Modell dadurch auch für Prognosen in komplexen und detaillierten Netzmodellen genutzt werden ohne aufwendige Berechnungsschritte durchzuführen und komplexe Modellformen wählen zu müssen.

Die Analyse der Routenwahl, und damit die Erstellung des Routenwahlmodells, erfolgt mittels multipler logistischer Regression. Die logistische Regression gehört zu den strukturprüfenden Verfahren und analysiert die Strukturen bzw. Zusammenhänge zwischen einer abhängigen Variablen, auch Response-Variable genannt, und mehreren unabhängigen Variablen, die auch als Prädiktor-Variablen bezeichnet werden (Backhaus, et al. 2016). Die Modellform folgt dem in Kapitel 2.2.2 beschriebenem Ansatz und ergibt nach der Schätzung der Konstanten und Koeffizienten mittels Maximum-Likelihood-Schätzung schließlich das Regressionsmodell.

Es existieren einige Voraussetzungen, die erfüllt sein müssen um eine logistische Regressionsanalyse durchführen zu können. Diese Voraussetzungen lauten wie folgt:

1. Die Response-Variable ist kategorial.
2. Die Prädiktor-Variablen sind metrisch oder im Falle kategorialer Variablen als Dummy-Variablen codiert.
3. Die Stichprobe muss ausreichend groß sein.
4. Für jede Gruppe, die durch kategoriale Prädiktoren gebildet wird, sollte $n \geq 25$ sein.
5. Es sollten möglichst wenige/keine Ausreißer im Datensatz vorhanden sein.
6. Es darf keine Multikollinearität bestehen (Korrelationen der Prädiktor-Variablen).

Die Prüfung der genannten Voraussetzung ergibt folgendes: Bei der abhängigen Variable handelt es sich um eine kategoriale Variable. Sie ist zum einen binär codiert (Wahl = 1, Ablehnung = 0). Darüber hinaus sind die Wahlmöglichkeiten (Alternativen) kategorial und für jede Fahrt im Datensatz einzeln gekennzeichnet (Voraussetzung 1).

Vorrausetzung 2 ist ebenfalls erfüllt, weil alle unabhängigen Variablen ein metrisches Skalenniveau aufweisen. Es existieren keine kategorialen unabhängigen Variablen, die als Dummy-Variablen codiert werden müssten.

Die Stichprobe sollte möglichst umfangreich, also genügend groß, für eine logistische Regressionsanalyse sein (Voraussetzung 3). Dies ist eine strikt einzuhaltende Voraussetzung, weil die Qualität der Schätzergebnisse mit zunehmender Fallzahl steigt. Wie groß

die Fallzahl sein sollte, um robuste Schätzwerte zu erhalten, ist nur schwer zu ermitteln. Nach Ullmann und Mehlhorn 2012 sollten pro Ausprägung der abhängigen Variable mindestens 25 Beobachtungen existieren. Aussagekräftige Schätzungen kann ein Modell erst ab ca. 100 Beobachtungen pro Variable liefern. Insgesamt liegt mit rund 18.500 Routen und den entsprechenden Alternativen eine genügend große Fallzahl vor.

Da alle unabhängigen Variablen (Prädiktoren) metrisch skaliert sind und somit keine Gruppe durch kategoriale Prädiktoren gebildet wird, ist Voraussetzung 4 ebenfalls erfüllt.

Voraussetzung 5 gibt an, dass die Daten möglichst keine Beobachtungen enthalten sollten, die keinen Beitrag zur Erklärung der Zusammenhänge leisten bzw. diese verzerren würden (Ausreißer). Mittel der Wahl ist es, Daten mit starken Ausreißern zu löschen. Das Beseitigen der einzelnen Ausreißer-Daten (Routen und Alternativen) ist jedoch sehr aufwendig und eine starke Reduktion der Datengrundlage wäre die Folge. Wenn alle Routen/Alternativen mit Ausreißern entfernt würden, so würden bspw. bei 73 Variablen mit jeweils nur 50 Ausreißern pro Variable, die sich nicht mit anderen Ausreißern decken, im Datensatz 3.650 Routen verloren gehen. Um den Datenverlust möglichst gering zu halten, wurden daher Verteilung, Streuung und Ausreißer der einzelnen Variablen innerhalb der Variablen-Kategorien genauer betrachtet.

Die Analyse zeigte sehr unterschiedliche Verteilungen der Variablen (siehe Anhang 5). Bei zahlreichen Variablen existiert eine Vielzahl von Beobachtungen, mit einer breiten Streuung und nur wenigen Ausreißern. Andere Variablen offenbaren wiederum nur wenige Beobachtungen oder eine sehr geringe Streuung der Werte bei gleichzeitig vielen und starken Ausreißern. Variablen mit vielen und starken Ausreißern wurden für die weiteren Analysen der Routenwahl nicht berücksichtigt. Dies ist nicht weiter problematisch, solang aus jeder Variablen-Kategorie mindestens eine sog. „Stellvertreter-Variable“ erhalten bleibt, um den Einfluss auf die Routenwahl zu analysieren. Ein oder zwei unterschiedliche Variablen, wie z.B. Asphalt oder Kopfsteinpflaster, der Kategorie Oberflächenqualität sind bspw. ausreichend, um den Einfluss glatter Oberfläche auf die Routenwahl zu analysieren.

Darüber hinaus war es notwendig, einige Variablen zu neuen Variablen innerhalb der Variablen-Kategorie zu aggregieren, weil die zuvor gewählte Unterscheidung (Variablen) eines Merkmals (Variablen-Kategorie) zu feingliedrig war und für die Variablen nur wenige Werte und starke Ausreißer vorhanden waren. So wurden die ursprünglich für den $DTV_{Rad}$ vorgesehenen sieben Variablen in zwei Variablen „$DTV_{Rad} < 500$“ und „$DTV_{Rad} > 500$“ zusammengefasst. Die ursprünglich neun Variablen der Kategorie „Radverkehrsführungsform“ musste ebenfalls in 2 Variablen („Radverkehrsinfrastruktur vorhanden“ und „keine

Radverkehrsinfrastruktur vorhanden“) zusammengefasst werden, um dem Kriterium einer möglichst großen Fallzahl und wenigen Ausreißern gerecht zu werden. Gleiches trifft auf die Variablen-Kategorie „Breite der Radverkehrsführung“ zu, in der die Variablen zu „Breite < 1,5 m“, „Breite > 1,5 m“ und „keine Breite“ aggregiert wurden. Eine weitere Aggregation war innerhalb der Variablen-Kategorie „Zulässige Höchstgeschwindigkeit des Kfz-Verkehrs“ notwendig. Das Ergebnis der Aggregation waren die Variablen „Max. zul. Geschwindigkeit des Kfz-Verkehrs < 30 km/h“ und „Max. zul. Geschwindigkeit des Kfz-Verkehrs > 30 km/h“. Eine ähnliche Aggregation wurde für die Variablen der Kategorie „Führungsform des Radverkehrs“ durchgeführt, sodass sich letztlich die Variablen „Radverkehrsinfrastruktur“ und „keine Radverkehrsinfrastruktur“ ergaben. Die Aggregation der einzelnen Variablen ist im Aggregationsschlüssel in Anhang 6 nachzuvollziehen.

Um darüber hinaus eine Verzerrung der Analyseergebnisse durch einen geringen Informationsgehalt der Variablen zu verhindern, wurden jene Attribute aus der Analyse ausgeschlossen, zu denen im Netzmodell, und dementsprechend entlang der Routen und Alternativen, nur sehr wenig Informationen vorlagen. Dies betrifft vor allem das Attribut „Sicherheitsraum“, für das im Mittel zu rund 96 % keine Informationen entlang der Routen/Alternativen vorliegen. Daneben existieren noch weitere Variablen aus unterschiedlichen Kategorien, für die nur sehr wenige Informationen entlang der Routen/Alternativen vorliegen (bspw. gebundene und ungebundene Oberflächen, die Radverkehrsführung auf Bussonderfahrstreifen, Regelung an Knotenpunkten). Diese Variablen wurden in der weiteren Analyse nicht berücksichtigt. Es wurden zudem die Variablen „k.A.“ (keine Angabe) aus dem Datensatz entfernt, weil sie keine zusätzlichen Informationen bieten, die für die Analyse zuträglich wären. Ausnahmen bildet lediglich die Variable „k.A.“ der Kategorie „Ruhender Verkehr“. Sie wurde für weiteren Betrachtungen zunächst im Datensatz belassen, weil ihr im Gegensatz zu den anderen „k.A.“-Variablen ein nicht unerheblicher Informationsgehalt unterstellt werden kann.[7]

Ergebnis der Datenbereinigung ist, dass insgesamt 29 Variablen für 13 der 14 Variablen-Kategorien im Datensatz verbleiben (die Kategorie „Sicherheitsraum“ konnte aufgrund mangelnder Daten und wegen zu starken Ausreißern nicht berücksichtigt werden). Eine Übersicht der final in die Analyse aufgenommen Variablen wird am Ende des Kapitels in Tabelle 5 gegeben.

[7] Im Nebennetz lagen häufig weniger Informationen zum ruhender Verkehr vor als im Hauptverkehrsnetz. Daher rühren meist die Werte der Variable „k.A.“, wenn Fahrten im Nebennetz durchgeführt wurden. Eine visuelle Überprüfung zeigte jedoch, dass im Nebennetz stadtweit ruhender Verkehr vorhanden ist. Daher kann angenommen werden, dass die Variable „k.A.“ einen Beitrag zur Erklärung leisten kann und als eine Art Indikator für die Existenz von ruhendem Verkehr im Nebennetz dienlich sein könnte.

Die letzte und eine der wesentlichsten Voraussetzungen ist, dass keine Multikollinearität besteht (Voraussetzung 6). Ein ideales Modell erhält man, wenn zwischen den Response-Variablen und den Prädiktor-Variablen eine möglichst hohe Korrelation besteht – zwischen den Prädiktor-Variablen aber möglichst keine. Multikollinearität besteht dann, wenn mehr als zwei Prädiktor-Variablen so stark miteinander korrelieren, dass sie einen hohen Korrelationskoeffizienten (z.B. r = 0,8) aufweisen. Sie ist für die logistische Regressionsanalyse problematisch, weil die Regressionskoeffizienten verzerrt werden können, wenn die Prädiktor-Variablen stark korrelieren. Das sich ergebende Modell bzw. die geschätzten Koeffizienten, die den Einfluss einer Variable auf die Wahl einer Route bestimmen, würden damit nicht der Realität entsprechen.

Um die Einhaltung der Voraussetzung zu prüfen und Multikollinearität festzustellen, wurde eine Korrelationsanalyse in SPSS durchgeführt. Dazu wurde für alle unabhängigen Variablen der Korrelationskoeffizient nach Bravais-Pearson bestimmt. Er berechnet sich nach

$$r_{BP} = \frac{\sum_{i=1}^{n}(x_i - \bar{x})\,(y_i - \bar{y})}{\sqrt{\left(\sum_{i=1}^{n}(x_i - \bar{x})^2\right)}\sqrt{\left(\sum_{i=1}^{n}(y_i - \bar{y})^2\right)}} \tag{32}$$

mit $r_{BP}$ als Korrelationskoeffizient nach Bravais-Pearson, $x_i$ und $y_i$ als Werte der beiden auf Korrelation zu prüfenden Variablen, $\bar{x}$ und $\bar{y}$ als Mittelwerte der Variablen und $n$ als Stichprobengröße.

Der Korrelationskoeffizient nimmt Werte zwischen -1 und +1 an und zeigt damit sowohl negative ($r < 0$) als auch positive ($r > 0$) Zusammenhänge auf. Demnach besteht kein Zusammenhang zwischen den Variablen, wenn $r = 0$ ist. Der Korrelationskoeffizient $r_{PB}$ kann zudem genutzt werden, um die Stärke der Zusammenhänge zu beurteilen, weil er selbst ein Maß für die Effektstärke darstellt. Es lassen sich jedoch keine allgemein gültigen Aussagen zum Wert tätigen. Ab welchem Wert ein starker Zusammenhang besteht hängt auch immer von der Problemstellung ab (Backhaus, et al. 2016). Als Orientierung wird in der Literatur häufig auf die Einteilung von Cohen 1988 verwiesen, nach der bspw. bis zu einem $r < 0{,}5$ von einem mittleren Zusammenhang gesprochen wird. Werte von $r > 0{,}7$ deuten auf einen starken Zusammenhang hin.

Das Ergebnis der Korrelationsanalyse ist, dass unterschiedlich starke Korrelationen zwischen den verbliebenen 28 Prädiktor-Variablen bestehen. Abbildung 29 stellt die Stärke der gefundenen Korrelation zwischen den verbleibenden Variablen grafisch dar (eine vollständige Korrelationsmatrix inkl. der Werte für *r* und den Signifikanzen ist in Anhang 7 dargestellt). Neben der deutlich hervortretenden Hauptdiagonalen (dunkelblau) sind vor allem punktuell positive (blau) und negative (rot) Korrelationen zu beobachten.

Bei den deutlich hervortretenden Korrelationen handelt es sich meist um Zusammenhänge innerhalb der Variablen-Kategorien. Eine Zu- oder Abnahme der Ausprägung einer Variable innerhalb einer Kategorie (siehe bspw. Variablen 11 und 12 oder 23 bis 25) führt zwangsläufig zu einer Zu- oder Abnahme der Ausprägung einer anderen Variable der gleichen Kategorie.

Da aufgrund der Gefahr von Multikollinearität vor allem solche Variablen nicht in die Analyse aufgenommen werden sollten, die starke und signifikante Korrelationen aufweisen, wurden zunächst die Variablen mit starken Korrelationen ($r > 0,7$) betrachtet. Darüber hinaus wurde geprüft, ob $r$ signifikant ist – also ein signifikanter Unterschied von Null besteht. Dies ist notwendig, um zu bestimmen, ob ein gefundener Zusammenhang auch signifikant ist – unabhängig davon, wie stark er ist. Die Signifikanz wurde im Rahmen der Korrelationsanalyse mit SPSS bestimmt (2-seitiger Test; Signifikanzniveau = 0,01).

Anschließend wurden die signifikant starken Zusammenhänge zwischen den Variablen genauer betrachtet. Insgesamt konnte für die folgenden Kombinationen, der in Abbildung 29 dargestellten Variablen, eine signifikante und starke Korrelation festgestellt werden:

- Zwischen Distanz (1) und Reisezeit (2) mit r = 0,7752
- Zwischen durchschnittlicher Längsneigung (3) und Längsneigung > 2% (6) mit r = 0,8004
- Innerhalb der Kategorie „Radverkehrsinfrastruktur“ zwischen (11) und (12) mit r = -0,9989
- Innerhalb der Kategorie „Breite der Radverkehrsführungsform“ zwischen (13) und (14) mit r = -1
- Zwischen Radverkehrsinfrastruktur (11) und der Breite der Radverkehrsführungsform mit r = -0,8052 (13) bzw. r = 0,8052 (14) sowie zwischen Radverkehrsinfrastruktur (12) und der Breite der Radverkehrsführungsform mit r = 0,8040 (13) bzw. r = -0,8039 (14)
- Innerhalb der Kategorie „Ruhender Verkehr“ zwischen den Variablen (18) und (19) mit r = -0,9668
- Innerhalb der Kategorie zum $DTV_{Rad}$ zwischen (22) und (23) mit r = -0,8062 und zwischen (22) und (24) mit r = 0,8062 sowie zwischen (23) und (24) mit r = -1

Ein probates Mittel zum Umgang mit Multikollinearität der Prädiktor-Variablen ist es die stark untereinander korrelieren Variablen nicht in die Analyse einfließen zu lassen (siehe Khatri, et al. 2016). Kritisch ist dieses Vorgehen nur dann, wenn dadurch wichtige

| | | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | 16 | 17 | 18 | 19 | 20 | 21 | 22 | 23 | 24 | 25 | 26 | 27 | 28 |
|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|
| 1 | Distanz | 1,00 | 0,78 | 0,09 | 0,45 | -0,05 | 0,02 | 0,07 | -0,03 | -0,17 | -0,13 | 0,20 | -0,20 | -0,19 | 0,19 | 0,10 | -0,23 | 0,04 | -0,22 | 0,23 | -0,21 | -0,01 | 0,16 | -0,09 | 0,09 | 0,27 | -0,23 | -0,09 | 0,02 |
| 2 | Reisezeit | 0,78 | 1,00 | 0,16 | 0,48 | -0,08 | 0,06 | -0,20 | 0,05 | -0,18 | -0,14 | -0,05 | 0,05 | 0,02 | -0,02 | 0,10 | -0,16 | -0,07 | -0,19 | 0,20 | -0,20 | -0,05 | -0,10 | 0,16 | -0,16 | 0,21 | -0,20 | -0,17 | -0,03 |
| 3 | Durchschn. Längsneigung | 0,09 | 0,16 | 1,00 | 0,64 | -0,51 | 0,80 | -0,26 | -0,03 | -0,34 | -0,18 | -0,23 | 0,23 | 0,19 | -0,19 | -0,03 | -0,05 | -0,18 | -0,20 | 0,22 | -0,23 | -0,20 | -0,25 | 0,28 | -0,28 | 0,23 | -0,07 | -0,13 | -0,11 |
| 4 | Maximale Längsneigung | 0,45 | 0,48 | 0,64 | 1,00 | -0,29 | 0,41 | -0,18 | -0,01 | -0,29 | -0,20 | -0,08 | 0,07 | 0,06 | -0,06 | 0,06 | -0,17 | -0,13 | -0,23 | 0,26 | -0,26 | -0,15 | -0,12 | 0,16 | -0,16 | 0,28 | -0,20 | -0,14 | -0,08 |
| 5 | Längsneigung < 2% | -0,05 | -0,08 | -0,51 | -0,29 | 1,00 | -0,30 | 0,17 | -0,02 | 0,21 | 0,07 | 0,12 | -0,12 | -0,09 | 0,09 | -0,03 | 0,05 | 0,09 | 0,14 | -0,15 | 0,17 | 0,10 | 0,12 | -0,14 | 0,14 | -0,12 | 0,08 | 0,11 | -0,00 |
| 6 | Längsneigung > 2% | 0,02 | 0,06 | 0,80 | 0,41 | -0,30 | 1,00 | -0,17 | -0,03 | -0,30 | -0,13 | -0,21 | 0,21 | 0,18 | -0,18 | -0,05 | -0,01 | -0,11 | -0,11 | 0,13 | -0,16 | -0,15 | -0,23 | 0,25 | -0,25 | 0,16 | -0,00 | -0,05 | -0,09 |
| 7 | OF - Asphalt | 0,07 | -0,20 | -0,26 | -0,18 | 0,17 | -0,17 | 1,00 | -0,20 | 0,17 | 0,09 | 0,38 | -0,38 | -0,27 | 0,27 | -0,08 | 0,02 | 0,17 | 0,35 | -0,36 | 0,29 | -0,01 | 0,50 | -0,48 | 0,48 | -0,04 | 0,08 | 0,51 | 0,02 |
| 8 | OF - Kopfsteinpflaster | -0,03 | 0,05 | -0,03 | -0,01 | -0,02 | -0,03 | -0,20 | 1,00 | 0,04 | 0,08 | -0,10 | 0,10 | 0,06 | -0,06 | -0,04 | 0,06 | -0,07 | 0,09 | -0,10 | 0,10 | -0,04 | 0,02 | -0,00 | 0,00 | -0,09 | -0,04 | 0,12 | -0,05 |
| 9 | Sicherheit (Unfallhäufigkeit) | -0,17 | -0,18 | -0,34 | -0,29 | 0,21 | -0,30 | 0,17 | 0,04 | 1,00 | 0,57 | 0,21 | -0,21 | -0,17 | 0,17 | 0,28 | -0,03 | 0,29 | 0,22 | -0,24 | 0,32 | 0,51 | 0,33 | -0,51 | 0,51 | -0,40 | 0,00 | 0,14 | 0,32 |
| 10 | Subj. Sicherheit (Krit. Sit.) | -0,13 | -0,14 | -0,18 | -0,20 | 0,07 | -0,13 | 0,09 | 0,08 | 0,57 | 1,00 | 0,26 | -0,26 | -0,18 | 0,18 | 0,30 | -0,09 | 0,17 | 0,06 | -0,07 | 0,01 | 0,46 | 0,28 | -0,42 | 0,42 | -0,30 | -0,14 | -0,07 | 0,46 |
| 11 | Radinfrastruktur vorhanden | 0,20 | -0,05 | -0,23 | -0,08 | 0,12 | -0,21 | 0,38 | -0,10 | 0,21 | 0,26 | 1,00 | -1,00 | -0,81 | 0,81 | 0,28 | -0,47 | 0,14 | -0,32 | 0,31 | -0,28 | 0,28 | 0,70 | -0,64 | 0,64 | 0,21 | -0,40 | -0,21 | 0,41 |
| 12 | K. Radinfrastruktur vorhanden | -0,20 | 0,05 | 0,23 | 0,07 | -0,12 | 0,21 | -0,38 | 0,10 | -0,21 | -0,26 | -1,00 | 1,00 | 0,80 | -0,80 | -0,28 | 0,47 | -0,14 | 0,32 | -0,31 | 0,28 | -0,28 | -0,70 | 0,63 | -0,63 | -0,21 | 0,40 | 0,21 | -0,41 |
| 13 | Breite Radinfrastruktur <1,5m | -0,19 | 0,02 | 0,19 | 0,06 | -0,09 | 0,18 | -0,27 | 0,06 | -0,17 | -0,18 | -0,81 | 0,80 | 1,00 | -1,00 | -0,29 | 0,40 | -0,17 | 0,29 | -0,28 | 0,26 | -0,27 | -0,52 | 0,54 | -0,54 | -0,20 | 0,33 | 0,17 | -0,33 |
| 14 | Breite Radinfrastruktur >1,5m | 0,19 | -0,02 | -0,19 | -0,06 | 0,09 | -0,18 | 0,27 | -0,06 | 0,17 | 0,18 | 0,81 | -0,80 | -1,00 | 1,00 | 0,29 | -0,40 | 0,17 | -0,29 | 0,28 | -0,26 | 0,27 | 0,52 | -0,54 | 0,54 | 0,20 | -0,33 | -0,17 | 0,33 |
| 15 | Mittlerer DTV des Kfz-Verkehrs | 0,10 | 0,10 | -0,03 | 0,06 | -0,03 | -0,05 | -0,08 | -0,04 | 0,28 | 0,30 | 0,28 | -0,28 | -0,29 | 0,29 | 1,00 | -0,37 | 0,42 | -0,23 | 0,24 | -0,23 | 0,48 | 0,02 | -0,19 | 0,19 | -0,21 | -0,22 | -0,17 | 0,69 |
| 16 | Max. zul. Geschw. Kfz < 30km/h | -0,23 | -0,16 | -0,05 | -0,17 | 0,05 | -0,01 | 0,02 | 0,06 | -0,03 | -0,09 | -0,47 | 0,47 | 0,40 | -0,40 | -0,37 | 1,00 | -0,43 | 0,45 | -0,47 | 0,51 | -0,33 | -0,26 | 0,24 | -0,24 | -0,26 | 0,57 | 0,27 | -0,29 |
| 17 | Max. zul. Geschw. Kfz > 30km/h | 0,04 | -0,07 | -0,18 | -0,13 | 0,09 | -0,11 | 0,17 | -0,07 | 0,29 | 0,17 | 0,14 | -0,14 | -0,17 | 0,17 | 0,42 | -0,43 | 1,00 | 0,06 | -0,05 | 0,05 | 0,52 | 0,04 | -0,26 | 0,26 | -0,37 | 0,00 | 0,27 | 0,31 |
| 18 | Ruhender Verkehr (längs) | -0,22 | -0,19 | -0,20 | -0,23 | 0,14 | -0,11 | 0,35 | 0,09 | 0,22 | 0,06 | -0,32 | 0,32 | 0,29 | -0,29 | -0,23 | 0,45 | 0,06 | 1,00 | -0,97 | 0,59 | -0,09 | -0,11 | -0,00 | 0,00 | -0,39 | 0,46 | 0,62 | -0,17 |
| 19 | k.A. zum ruhenden Verkehr | 0,23 | 0,20 | 0,22 | 0,26 | -0,15 | 0,13 | -0,36 | -0,10 | -0,24 | -0,07 | 0,31 | -0,31 | -0,28 | 0,28 | 0,24 | -0,47 | -0,05 | -0,97 | 1,00 | -0,61 | 0,09 | 0,11 | 0,00 | -0,00 | 0,40 | -0,45 | -0,64 | 0,18 |
| 20 | KP-Regelung: rechts vor links | -0,21 | -0,20 | -0,23 | -0,26 | 0,17 | -0,16 | 0,29 | 0,10 | 0,32 | 0,01 | -0,28 | 0,28 | 0,26 | -0,26 | -0,23 | 0,51 | 0,05 | 0,59 | -0,61 | 1,00 | -0,13 | -0,10 | -0,02 | 0,02 | -0,41 | 0,53 | 0,54 | -0,19 |
| 21 | KP-Regelung: LSA | -0,01 | -0,05 | -0,20 | -0,15 | 0,10 | -0,15 | -0,01 | -0,04 | 0,51 | 0,46 | 0,28 | -0,28 | -0,27 | 0,27 | 0,48 | -0,33 | 0,52 | -0,09 | 0,09 | -0,13 | 1,00 | 0,20 | -0,41 | 0,41 | -0,32 | -0,19 | -0,08 | 0,49 |
| 22 | Mittlerer DTV-Rad | 0,16 | -0,10 | -0,25 | -0,12 | 0,12 | -0,23 | 0,50 | 0,02 | 0,33 | 0,28 | 0,70 | -0,70 | -0,52 | 0,52 | 0,02 | -0,26 | 0,04 | -0,11 | 0,11 | -0,10 | 0,20 | 1,00 | -0,81 | 0,81 | 0,17 | -0,32 | -0,10 | 0,14 |
| 23 | DTV-Rad < 500 | -0,09 | 0,16 | 0,28 | 0,16 | -0,14 | 0,25 | -0,48 | -0,00 | -0,51 | -0,42 | -0,64 | 0,63 | 0,54 | -0,54 | -0,19 | 0,24 | -0,26 | -0,00 | 0,00 | -0,02 | -0,41 | -0,81 | 1,00 | -1,00 | 0,04 | 0,26 | -0,08 | -0,28 |
| 24 | DTV-Rad > 500 | 0,09 | -0,16 | -0,28 | -0,16 | 0,14 | -0,25 | 0,48 | 0,00 | 0,51 | 0,42 | 0,64 | -0,63 | -0,54 | 0,54 | 0,19 | -0,24 | 0,26 | 0,00 | -0,00 | 0,02 | 0,41 | 0,81 | -1,00 | 1,00 | -0,04 | -0,26 | 0,08 | 0,28 |
| 25 | Grünflächen | 0,27 | 0,21 | 0,23 | 0,28 | -0,12 | 0,16 | -0,04 | -0,09 | -0,40 | -0,30 | 0,21 | -0,21 | -0,20 | 0,20 | -0,21 | -0,26 | -0,37 | -0,39 | 0,40 | -0,41 | -0,32 | 0,17 | 0,04 | -0,04 | 1,00 | -0,42 | -0,34 | -0,22 |
| 26 | Wohnflächen | -0,23 | -0,20 | -0,07 | -0,20 | 0,08 | -0,00 | 0,08 | -0,04 | 0,00 | -0,14 | -0,40 | 0,40 | 0,33 | -0,33 | -0,22 | 0,57 | 0,00 | 0,46 | -0,45 | 0,53 | -0,19 | -0,32 | 0,26 | -0,26 | -0,42 | 1,00 | 0,34 | -0,24 |
| 27 | 1 Fahrstreifen Kfz-Verkehr | -0,09 | -0,17 | -0,13 | -0,14 | 0,11 | -0,05 | 0,51 | 0,12 | 0,14 | -0,07 | -0,21 | 0,21 | 0,17 | -0,17 | -0,17 | 0,27 | 0,27 | 0,62 | -0,64 | 0,54 | -0,08 | -0,10 | -0,08 | 0,08 | -0,34 | 0,34 | 1,00 | -0,37 |
| 28 | > 1 Fahrstreifen Kfz-Verkehr | 0,02 | -0,03 | -0,11 | -0,08 | -0,00 | -0,09 | 0,02 | -0,05 | 0,32 | 0,46 | 0,41 | -0,41 | -0,33 | 0,33 | 0,69 | -0,29 | 0,31 | -0,17 | 0,18 | -0,19 | 0,49 | 0,14 | -0,28 | 0,28 | -0,22 | -0,24 | -0,37 | 1,00 |

r = -1 … 0 … 1

Abbildung 29: Korrelationsmatrix der unabhängigen Variablen. Dargestellt ist der Korrelationskoeffizient nach Bravais-Pearson $r_{BP}$

Informationen nicht berücksichtigt werden können. Das Reduzieren des Variablen-Sets muss daher gut begründet sein. Für die Analyse wurden jene Variablen aus dem Variablen-Set entfernt, die stark korrelieren und deren Entfernen zu keinem oder nur einem sehr geringen Informationsverlust führen. Dies ist immer dann der Fall, wenn aus jeder Prädiktoren-Kategorie mindesten eine Variable oder eine Auswahl an Variablen im gesamten Variablen-Set enthalten bleiben. Dadurch bleiben die relevanten Informationen durch sog. „Stellvertreter-Variablen" einer Prädiktor-Kategorie erhalten.

Das Variablen-Set wurde entsprechend den beschriebenen Prämissen reduziert. Es wurden alle Variablen a) mit ungenügendem Informationsgehalt (wenige Datenpunkte), b) vielen und starken Ausreißern und c) starker Korrelation entfernt. Die 20 Variablen, die für die Analyse im Variablen-Set verbleiben und in die Regressionsanalyse eingeschlossen wurden, sind in Tabelle 5 aufgeführt.

| **Einflussfaktor (Prädiktor-Kategorie)** | **Prädiktor-Variable** | **Variable im Modell** |
|---|---|---|
| Distanz/Reisezeit | Distanz [km] | $dist_i$ |
| Längsneigung | Maximale Längsneigung entlang der Route [%] | $LNmax_i$ |
| | Routenanteil mit einer Längsneigung < 2% [%] | $LN < 2\%_i$ |
| | Routenanteil mit einer Längsneigung > 2% [%] | $LN > 2\%_i$ |
| Oberflächenbeschaffenheit | Anteil Asphaltoberfläche [%] | $AS_i$ |
| | Anteil Kopfsteinpflasteroberfläche [%] | $KS_i$ |
| Sicherheit | Unfallhäufigkeit entlang der Route [n/km] | $UH_i$ |
| | Häufigkeit kritischer Situationen entlang der Route [n/km] | $HKS_i$ |
| Radverkehrsführungsform | Streckenanteil mit Radverkehrsinfrastruktur [%] | $RVI_i$ |
| Breite der Radverkehrsführung | Anteil der Radverkehrsführung mit einer Breite <1,5 m [%] | $BR_i$ |
| Sicherheitsraum | - | – |
| Kraftfahrzeugverkehrsstärke ($DTV_{Kfz}$) | Mittlerer DTV des Kfz-Verkehrs entlang der Route [n] | $DTVKfz_i$ |
| Zulässige Höchstgeschwindigkeit des Kfz-Verkehrs | Anteil der Strecken entlang der Route mit v < 30 km/h [%] | $v < 30_i$ |
| Ruhender Verkehr (RV) | Anteil längs angeordneten RV entlang der Route [%] | $RVL_i$ |
| Knotenpunkte (KP) und deren Regelung | Häufigkeit von KP mit Regelung „rechts-vor-links" [n/km] | $KPrvl_i$ |
| | Häufigkeit von LSA-geregelten KP [n/km] | $KPLSA_i$ |
| Radverkehrsaufkommen | Anteil der Strecken entlang der Route mit $DTV_{Rad}$ > 500 [%] | $DTVRAD_i$ |
| Flächennutzung | Grünflächenanteil entlang der Route [%] | $GFA_i$ |
| | Anteil von Wohngebietsflächen entlang der Route [%] | $WGA_i$ |
| Anzahl Fahrstreifen | Streckenanteil mit einem Fahrstreifen [%] | $FS1_i$ |

Tabelle 5: In die Analyse aufgenommene Prädiktor-Variablen

Die Modellformulierung folgt im Wesentlichen dem in Kapitel 2.2.2 beschriebenen Ansatz der multiplen logistischen Regressionsanalyse. Es ergibt sich jedoch eine Besonderheit bzgl. des genutzten Logit-Modells. Die Statistik-Software SPSS, mit der die Analyse

durchgeführt wird, verfügt mit der binärlogistischen und der multinomialen logistischen Regression zwar über Verfahren zur Analyse diskreter Entscheidungen. Diese sollten aber nur dann genutzt werden, wenn das Modell nur Merkmale der Subjekte oder Individuen enthält (z.B. bei der Analyse zum Kauf eines Fahrzeugs [abhängige Variable] auf Basis von Personeneigenschaften [unabhängige Variablen]) (IBM-a 2020). In diesem Fall würde das Modell die Form eines klassischen multinomialen logistischen Regressionsmodells annehmen (siehe Kapitel 2.2.2).

Sollen jedoch Entscheidungen analysiert werden, die vor allem auf Basis der Merkmale der Auswahloptionen (z.B. Routenalternativen) getroffen werden, dann sollte das Conditional Logit von McFadden, das manchmal vereinfacht als multinomiales Logit bezeichnet wird, genutzt werden (Rodríguez 2020). Nach McFadden sollte der Nutzen einer Alternative, und damit auch die Auswahlwahrscheinlichkeit, besser auf Grundlage der Eigenschaften der Alternativen analysiert und modelliert werden (McFadden 1973).

Das von McFadden vorgeschlagene Conditional Logit kann in SPSS über das sog. COXREG-Verfahren durchgeführt werden (IBM-a 2020). Input des Verfahrens sind die Routen und Alternativen mit ihren Eigenschaften. In dem Verfahren kann einer gewählten Route jedoch jeweils nur eine nicht gewählte Alternative gegenübergestellt bzw. zugeordnet werden. Die Einschränkung auf den 1:1 Fall hat zur Folge, dass nur eine der zwei generierten Alterativen für die Analyse genutzt werden kann. Diese Festlegung wird allerdings nicht als problematisch angesehen, da Radfahrende im Mittel nur 2,3 Routenalternativen (Median = 2) auf alltäglichen Wegen kennen bzw. nutzen (Friedrich 2019). Für die Analyse wurde jeweils die zuletzt generierte Alternative (2) genutzt, da sie räumlich weniger nahe an der Originalroute liegt und somit einen deutlichen Unterschied zur gewählten Route verspricht.

Anschließend wird die Entscheidung auf Basis der Eigenschaften der Route bzw. der Alternative analysiert. Dies geschieht über die Maximierung der sog. *conditional partial likelihood* (IBM-b 2020). Die Regressionskoeffizienten des Modells werden bestimmt, indem für die beobachteten Werte möglichst hohe Wahrscheinlichkeiten voraussagt werden, wenn die Response-Variable = 1 ist (bzw. möglichst geringe Wahrscheinlichkeiten, wenn die Response-Variable = 0 ist). Der von SPSS genutzte Algorithmus maximiert dabei eine Likelihood-Funktion (ähnlich der MLE), die aussagt, wie wahrscheinlich es ist, dass der Wert einer Response-Variable durch die Prädiktor-Variablen vorausgesagt werden kann.

Aus den Beschreibungen in Kapitel 2.2.2 und den in diesem Abschnitt formulierten Inhalten und Anpassungen ergibt sich für den deterministischen Nutzen des Analysemodells die Linearkombination

$$z(x) = \beta_{dist} * dist_i + \beta_{LNmax} * LNmax_i + \beta_{LN<2\%} * LN < 2\%_i + \beta_{LN>2\%} * LN > 2\%_i + \beta_{RVI} * RVI_i + \beta_{BR} * BR_i + \beta_{AS} * AS_i + \beta_{KS} * KS_i + \beta_{DTVRAD} * DTVRAD_i + \beta_{DTVKfz} * DTVKfz_i + \beta_{FS1} * FS1_i + \beta_{v<30} * v < 30_i + \beta_{RVL} * RVL_i + \beta_{UH} * UH_i + \beta_{HKS} * HKS_i + \beta_{KPrvl} * KPrvl_i + \beta_{KPLSA} * KPLSA_i + \beta_{GFA} * GFA_i + \beta_{WG} * WGA_i \quad (33)$$

mit $\beta_x$ als Regressionskoeffizienten der unabhängigen Variablen *X* sowie den jeweiligen Ausprägungen der unabhängigen Variablen *X* einer Alternative *i*. Die Zuordnung der Variablen zu den Routeneigenschaften ist in Tabelle 5 dargestellt. Aufgrund des Modell-Typs entfällt die alternativenspezifische Konstante $\beta_0$ (Vgl. Kapitel 2.2.2), weil keine alternativenspezifische Eigenschaften der Routen/Alternativen bestehen (z.B. kürzester oder komfortabelster Weg) und damit keine globale Präferenz einer Alternative bestimmt werden kann.

Eine Analyse des Einflusses von personenspezifischen Merkmalen würde bei dem genutzten COXREG-Verfahren keine Ergebnisse liefern, weil die zwei Alternativen (gewählte Route und nicht gewählte Alternative) „gekoppelt“ werden. Da die Variablen Alter und Geschlecht sowohl bei der Route als auch bei der Alternative identisch sind, würde die Modellschätzung kein Resultat hervorbringen. Um den Einfluss personenspezifischer Merkmale auf die Routenwahl zu prüfen, müssten also zusätzliche Modelle für Männer und Frauen gekreuzt mit z.B. unterschiedlichen Altersklassen geschätzt werden. Aus Gründen des Umfangs dieser Arbeit wurde davon abgesehen.

Die Analyse bzw. Modellschätzung wurde schließlich mit der Statistik-Software IBM SPSS (Version 27) durchgeführt.

### 4.3.2 Bestimmung der Modell-Güte

Nachdem eine Modellschätzung durchgeführt wurde, muss dessen Modell-Güte geprüft werden. Zur Bestimmung der Modell-Güte des Regressionsmodells lassen sich unterschiedliche Verfahren nutzen. Üblicherweise werden dazu Güte-Maße zur Beurteilung des Gesamtmodells sowie zur Beurteilung der einzelnen Regressionskoeffizienten berechnet. In den folgenden Abschnitten werden zunächst die Güte-Maße der Koeffizienten beschrieben und dann die Maße zur Bestimmung der Gesamtgüte des Modells erläutert. Die anschließenden Ausführungen folgen im Wesentlichen (Backhaus, et al. 2016).

**Signifikanz der Regressionskoeffizienten**

Mit einem Test wird zunächst geprüft, ob die Regressionskoeffizienten des Modells signifikant sind. Dazu kann für jeden der im Modell vorhandenen Regressionskoeffizienten der sog. Wald-Test durchgeführt werden. Mit diesem Test wird die Verteilung einer geeigneten Teststatistik unter Gültigkeit der Nullhypothese bestimmt. Die Teststatistik berechnet sich nach

$$w = \frac{\beta_j}{SE_{\beta_j}} \tag{34}$$

mit $\beta_j$ als Regressionskoeffizient einer Variable $j$ und $SE$ als dem Standardfehler von $\beta_j$. Die Ergebnisse des Wald-Tests zeigen, ob die Regressionskoeffizienten des Modells signifikant sind. Sind die Koeffizienten der unabhängigen Variablen signifikant (sign. < 0,05), dann haben sie einen signifikanten Einfluss auf die abhängige Variable.

**Odds Ratio (OR)**

Der Einfluss einer unabhängigen Variable wird über die Odds Ratio (in SPSS als Exp(B) bezeichnet) interpretiert. Die Odds Ration (OR) ist ein gebräuchliches Maß, um die Stärke von Zusammenhängen zu quantifizieren. Sie berechnet sich für die einzelnen Variablen aus dem Regressionskoeffizienten der unabhängigen Variable und der e-Funktion, also nach

$$OR_{\beta_j} = e^{\beta_j} \tag{35}$$

Die OR ist relativ einfach zu interpretieren. Nimmt die Odds Ratio nicht den Wert 1 an, so kann von einem signifikanten Einfluss der unabhängigen auf die abhängige Variable ausgegangen werden. Ist sie größer 1, so ist von einem positiven Zusammenhang auszugehen und die unabhängige Variable hat einen positiven Einfluss auf die abhängige Variable. Ist die OR kleiner als 1, so hat die unabhängigen Variable einen negativen Einfluss auf die abhängige Variable. Je weiter die Odds Ratio von dem Wert 1 entfernt ist, desto stärker ist der Zusammenhang.

**Log-Likelihood**

Da für die Schätzung des Modells die MLE verwendet wurde, kann der Wert der maximierten Log-Likelihood (LL) für die Beurteilung der Modell-Güte verwendet werden (Backhaus, et al. 2016). Bei der Nutzung der LL wird jedoch statt der LL meist der Wert −2LL ( = −2 * LL) genutzt. Umso kleiner der Wert der −2LL, umso höher ist die Anpassungsgüte des Modells. Die absolute Größe dieses Wertes sagt jedoch wenig aus (sowohl LL als auch –2LL stellen aufsummierte Werte dar), weil sie von der Anzahl der Beobachtungen abhängig sind. Eine Verdopplung der Beobachtungen würde folglich zu einer Verdopplung des –2LL führen, obwohl sich an den Schätzwerten nichts ändert.

Um dennoch einen Eindruck von der Modell-Güte zu erlangen, wird die –2LL des Modells üblicherweise der–2LL eines sog. Null-Modells gegenübergestellt. Das Null-Modell beinhaltet nur die Konstante und keine der Prädiktor-Variablen. Liegt der Wert des Null-Modells über dem Wert des Gesamtmodells (inkl. der Prädiktor-Variablen), so bedeutet dies, dass der Einbezug der Prädiktor-Variablen zu einer höheren Modell-Güte führt. Die Werte (LL, –2LL) können im Rahmen der Modellschätzung von der genutzten Software ausgegeben und anschließend verglichen werden.

**Likelihood-Ratio-Test**

Ein wichtiger Test für die Prüfung der Modell-Güte ist der sog. Likelihood-Ratio-Test. Der Test wird oft auch als Likelihood-Quotienten-Test bezeichnet. Die Likelihood Ratio (LLR) berechnet sich nach

$$LLR = -2 * \ln\left(\frac{L_0}{L_{ges}}\right) = -2 * (LL_0 - LL_{ges}) \tag{36}$$

$LL_0$ bezeichnet dabei die maximierte Log-Likelihood (LL) für das Null-Modell und $LL_{ges}$ die maximierte *LL* für das Gesamt-Modell. Je größer die Differenz zwischen den Modellen ist, desto besser ist das Modell.

Das Ergebnis kann darüber hinaus dafür genutzt werden, um zu testen, ob das Gesamtmodell signifikant ist und der Einbezug der Variablen einen signifikanten Erklärungsbeitrag liefert. Mit der Nullhypothese $H0: \beta_1 = \beta_2 = \ldots = \beta_n = 0$ (also unter der Annahme, dass die Korrelationskoeffizienten der Variablen keinen signifikanten Beitrag zur Erklärung der Zusammenhänge liefern) ist die LLR mit *n* Freiheitsgraden annähernd $\chi^2$-verteilt. Daher kann die LLR mit den *n* Freiheitsgraden der $\chi^2$-Verteilung gegenübergestellt und die Signifikanz ermittelt werden. Ist die LLR größer als der tabellierte $\chi^2$-Wert, kann die Nullhypothese abgelehnt und das Modell als signifikant angesehen werden. Ist der Wert größer, ist die Nullhypothese anzunehmen und das Modell verfügt über keinen signifikanten Erklärungsgehalt.

**Pseudo-$R^2$-Statistiken**

Darüber hinaus helfen sog. Pseudo-$R^2$-Statistiken die Modell-Güte einzuschätzen. In Analogie zum $R^2$ bei der linearen Regression werden die Pseudo-$R^2$-Statistiken im Rahmen der logistischen Regression genutzt. Gebräuchliche Maße sind das McFadden-$R^2$, das Cox&Snell-$R^2$ sowie das Nagelkerke's-$R^2$. Sie können ähnlich wie das $R^2$ bei der linearen Regression interpretiert werden. Allerdings ähneln sie dem $R^2$ der linearen Regression nur insofern, als dass ihr Wertebereich zwischen 0 und 1 liegt (Backhaus, et al. 2016). Ähnlich der linearen Regression kommt ein höheres $R^2$ einer besseren Anpassung gleich.

Das McFadden-$R^2$ ist ein wichtiges Güte-Maß. Es berechnet sich nach

$$R^2_{McF} = 1 - \left(\frac{LL_{ges}}{LL_0}\right) \tag{37}$$

und wird durch den Quotienten der LL des Null-Modells und des gesamt-Modells gebildet. Bei geringen Unterschieden der LL beider Modelle ist der Quotient nahe 1 und das McF-$R^2$ dementsprechend nahe 0. Das Erreichen eines McF-$R^2$ = 1 gilt bei realen Daten allgemeinhin als nahezu unmöglich (perfekte Anpassung). Die Werte des McF-$R^2$ liegen in der Praxis deutlich niedriger als beim $R^2$ von Modellen der linearen Regression. Nach Backhaus, et al. 2016 deuten bereits Werte zwischen 0,2 und 0,4 auf eine gute Modellanpassung hin.

Das bereits genannte Cox&Snell-$R^2$ berechnet sich nach

$$R^2_{CS} = 1 - e^{\left(\frac{-2}{n}[LL_{ges} - LL_0]\right)} \tag{38}$$

mit *LL* als Log-Likelihood der beiden Modelle und *n* als Fallzahl (UZH 2020). Das Cox&Snell-$R^2$ kann nur Werte kleiner 1 annehmen, weil $L_0$ stets größer 0 ist. Das bedeutet, dass es selbst bei einer perfekten Anpassung Werte liefern wird, die kleiner als 1 sind. Der resultierende Wert ist daher schwer zu interpretieren (Backhaus, et al. 2016). Seine Höhe kann jedoch Hinweise auf die Modell-Güte geben (Werte nahe 0 entsprechen dabei einer eher geringen Modell-Güte).

Das Nagelkerke's $R^2$ basiert auf dem Cox&Snell-$R^2$ und modifiziert es derart, dass auch der Maximalwert (1) erreicht werden kann. Es berechnet sich nach

$$R^2_N = \frac{R^2_{CS}}{1 - e^{\left(\frac{2}{n}LL_0\right)}} \tag{39}$$

(UZH 2020). Die Werte des Cox&Snell-$R^2$ sind daher ähnlich wie das $R^2$ bei der linearen Regressionsanalyse oder dem McF-$R^2$ zu interpretieren. Werte nahe 1 zeigen eine hohe Modell-Güte an; Werte nahe 0 eine sehr geringe (Backhaus, et al. 2016).

**Klassifikationsstatistik**

Als weiteres Maß zur Beurteilung der Modell-Güte kann die Klassifikationsstatistik des Modells herangezogen werden. Sie gibt Auskunft darüber, wie gut das Modell die Wahl einer Route (Annahme vs. Ablehnung) voraussagt (Backhaus, et al. 2016). Tabelle 6 stellt die Klassifikationsstatistik beispielhaft in Form der sog. *Confusion Matrix* dar. Die *Confusion Matrix* zeigt an, wie exakt das geschätzte Modell die Wahl für die vorliegenden Fälle (z.B. Wahl und Ablehnung von Routen) prognostiziert. Sie stellt die Beobachtungen in den Daten den Vorhersagen des Modells gegenüber. Nach Powers 2007 können in der *Confusion Matrix* die folgenden Fälle auftreten:

***True positives***: Wurde für einen Fall im Datensatz y = 1 beobachtet (z.B. Route gewählt – also positiv) und dieser auch durch das Modell als positiv erkannt (y = 1), dann wird der Fall als sog. *true positive* bezeichnet.

***True negatives***: Wurde für einen Fall im Datensatz y = 0 beobachtet (z.B. Route nicht gewählt – also negativ) und dieser auch durch das Modell als negativ erkannt (y = 0), dann wird der Fall als sog. *true negative* bezeichnet.

***False positives***: Wurde für einen Fall im Datensatz y = 0 beobachtet (z.B. Route nicht gewählt – also negativ), dieser jedoch fälschlicherweise durch das Modell als positiv erkannt (y = 1), dann wird der Fall als sog. *false positive* bezeichnet.

***False negatives***: Wurde für einen Fall im Datensatz y = 1 beobachtet (z.B. Route gewählt – also positiv), dieser jedoch fälschlicherweise durch das Modell als negativ erkannt (y = 0), dann wird der Fall als sog. *false negative* bezeichnet.

| | | **Vorhergesagt** | |
|---|---|---|---|
| | | Ja (y=1) | Nein (y=0) |
| **Beobachtet** | Ja (y=1) | True Positives | False Negatives |
| | Nein (y=0) | False Positives | True Negatives |

Tabelle 6: Confusion Matrix zur Gegenüberstellung der beobachteten und der vorhergesagten Werte. Richtige Vorhersagen sind in Grün, falsche in Blau hinterlegt. (Eigene Darstellung nach Powers 2007)

Aus den richtig und falschen Vorhersagen kann anschließend ein Prozentsatz der richtigen Vorhersagen ausgegeben werden (jeweils für y = 1 und y = 0). Die Berechnung des Prozentsatzes erfolgt über die berechnete Wahrscheinlichkeit für die abhängige Variable und einen festzulegenden Trennwert (meist 0,5 bzw. 50 %). Liegt die Wahrscheinlichkeit über dem Trennwert, so ist y = 1 (Wahl einer Route), andernfalls y = 0 (Ablehnung). Aus den einzelnen Werten der richtigen Vorhersagen kann schließlich ein Gesamtprozentsatz der richtigen Vorhersagen berechnet werden (Backhaus, et al. 2016).

Mit Hilfe der beschriebenen Fälle lassen sich unterschiedliche Maße berechnen, mit denen eine Aussage über die Modell-Güte getroffen werden kann. Diese sind:

**True positive rate (Recall)**

Die *true positive rate* oder *hit rate* – oft auch als *recall* bezeichnet – gibt den Anteil der vom Modell korrekt erkannten positiven Klassen aus. Sie berechnet sich nach

$$Recall = \frac{TP}{P} \tag{40}$$

aus der Anzahl der True Positives *TP* und den insgesamt vorhandenen Positives *P* (Roth und Friedrich 2016, Sabel 2012).

**True negative rate (TNR)**

Die TNR – auch *correct rejection rate* genannt – funktioniert analog zum Recall, fokussiert jedoch auf den Anteil der vom Modell korrekt erkannten negativen Klassen. Sie berechnet sich nach

$$TNR = \frac{TN}{N} \tag{41}$$

aus der Anzahl der True Negatives *TN* und den insgesamt vorhandenen negatives *N* (Roth und Friedrich 2016, Sabel 2012).

**Accuracy**

Mit der Accuracy kann erkannt werden, wie viel Prozent der Testinstanzen korrekt vom trainierten Modell erkannt wurden. Sie entspricht also dem einfachen Anteil der korrekt erkannten bzw. klassifizierten Testinstanzen und berechnet sich nach

$$Accuracy = \frac{TP + TN}{P + N} \tag{42}$$

aus der Anzahl der True Positives *TP* und True Negatives *TN* sowie der insgesamt vorhandenen positives *P* und negatives *N* (Arndt 2016, Roth und Friedrich 2016).

**Precision**

Die sog. Precision gibt das Vertrauensniveau der als positives klassifizierten Fälle an und bezieht damit alle als positiv klassifizierten Instanzen mit ein. Sie wird pro Klasse berechnet und berechnet sich nach

$$Precision = \frac{TP}{TP + FP} \tag{43}$$

aus der Anzahl der True Positives *TP* und False Positives *FP*. Das Ergebnis gibt den Anteil der richtigen unter den als richtig klassifizierten Instanzen aus (Roth und Friedrich 2016, Sabel 2012).

**F-Maß**

Das sogenannte F-Maß ist das harmonische Mittel aus den zuvor benannten Maßen Recall und Precision. Es berechnet sich nach

$$F = 2 * \frac{(Precision * Recall)}{(Precision + Recall)} \tag{44}$$

aus den zuvor berechneten Werten von Precision und Recall (Roth und Friedrich 2016, Sabel 2012).

Man muss bei geschätzten Modellen immer mehrere Maße beachten, da die Betrachtung von nur einem Maß keine korrekte Einschätzung der Modell-Güte ergibt.

**Prognose mit unbekannten Daten**

Eine weitere Möglichkeit für die Bestimmung der Modell-Güte besteht darin, mit dem Modell die Wahl/Ablehnung von Routen/Alternativen für einen Test-Datensatz zu berechnen, der nicht für die Modellschätzung genutzt wurde. Dieses Verfahren geht über viele der genannten Validierungsverfahren hinaus, da das Modell Prognosen für einen Datensatz unbekannter Nutzer*innen und Routen berechnen muss, die kein Teil des Schätzdatensatzes sind.

Die Anwendung der Methode erlaubt vor allem das Aufdecken einer sog. Überanpassung – einer zu spezifischen Anpassung eines Modells an eine Stichprobe. Eine evtl. vorhandene Überanpassung muss aufgedeckt und sollte nach Möglichkeit vermieden werden, weil sie eine tatsächlich geringere Modell-Güte verschleiert. In diesem Fall würde ein Modell die Daten der (Schätz-) Stichprobe zwar besser reproduzieren. Es könnte jedoch nicht auf andere Datensätze übertragen werden (fehlende Generalität). Daher wären die Ergebnisse eines solchen Modells zu hinterfragen und die Übertragbarkeit auf die Grundgesamtheit nicht gewährleistet.

Für diese Methode wurde auf einen für das geschätzte Modell unbekannten Datensatz aus dem Projekt *„Radverkehrsverhaltensstudie (RadVerS): Mit Smartphones generierte Verhaltensdaten im Verkehr“* zurückgegriffen. Die in dem Projekt erhobenen Routendaten besitzen das gleiche Format wie die im Projekt MOVEBIS erhobenen Daten und wurden mit exakt dem gleichen Verfahren aufbereitet (siehe Kapitel 4.2.1.2 bis Kapitel 4.2.6). Ergebnis der Aufbereitung ist eine Tabelle mit Informationen zu den gewählten Routen und den nicht gewählten Alternativen – analog zu den Daten für die Modellschätzung. Anschließend können mit dem ermittelten Regressionsmodell Prognosen für die Wahl einer Route für diesen Datensatz berechnet und mit der tatsächlichen Wahl verglichen werden.

## 4.4 Zusammenfassung und Ablaufbeschreibung

Da das methodische Vorgehen eine Vielzahl von einzelnen Schritten umfasst, die auf unterschiedliche Art und Weise zusammenwirken und teils ineinandergreifen, wird das Zusammenwirken der Schritte in dem folgenden Abschnitt noch einmal in seiner Gesamtheit dargestellt. Abbildung 30 verdeutlich die Zusammenhänge graphisch.

Die zu Beginn der Arbeit durchgeführte Literaturrecherche (siehe Kapitel 3.1) ergab einen Überblick über den aktuellen Stand der Forschung zur vorliegenden Thematik. Das Ergebnis der Recherche war, dass für den deutschen Raum keine Erkenntnisse zur Routenwahl von Radfahrenden und deren Einflussfaktoren auf Basis GPS-basierter Daten zum real beobachteten Verhalten vorliegen und Ergebnisse anderer Studien nicht übertragbar sind (siehe Kapitel 3.3).

Ausgehend von diesen Ergebnissen wurden zur Beantwortung der in Kapitel 1.3 formulierten Forschungsfragen das in Abbildung 30 visualisierte Forschungsdesign realisiert. Dazu wurden im Rahmen der Aktion STADTRADELN Routendaten von Radfahrenden in Dresden per Smartphone-App erhoben und die aufgezeichneten GPS-Tracks derart aufbereitet, dass nach der Primärdatenaufbereitung alltägliche Radfahrten für die Analysen zur Verfügung standen (siehe Kapitel 4.2.1).

Um den Einfluss diverser Faktoren auf die Routenwahl analysieren zu können, mussten die Eigenschaften der gewählten Routen bestimmt werden. Dazu wurden die notwendigen Sekundärdaten recherchiert, erhoben, aufbereitet und in einem Verkehrsangebotsnetz hinterlegt (siehe Kapitel 4.2.1 bis Kapitel 4.2.3).

Durch die Zuordnung der Routen zu den genutzten Streckensegmenten im Angebotsnetz (siehe Kapitel 4.2.4) konnten in einem nächsten Schritt die Eigenschaften der Routen aus dem Angebotsnetz ermittelt werden (siehe Kapitel 4.2.6). Für die Analyse der Routenwahl wurden den genutzten Routen die nicht genutzten Alternativen gegenübergestellt (siehe Kapitel 4.2.5). Die resultierenden und mit Eigenschaften versehenen Routen sowie die nicht gewählten Routenalternativen fanden schließlich Eingang die statistische Schätzung des logistischen Regressionsmodells (siehe Kapitel 4.3.1).

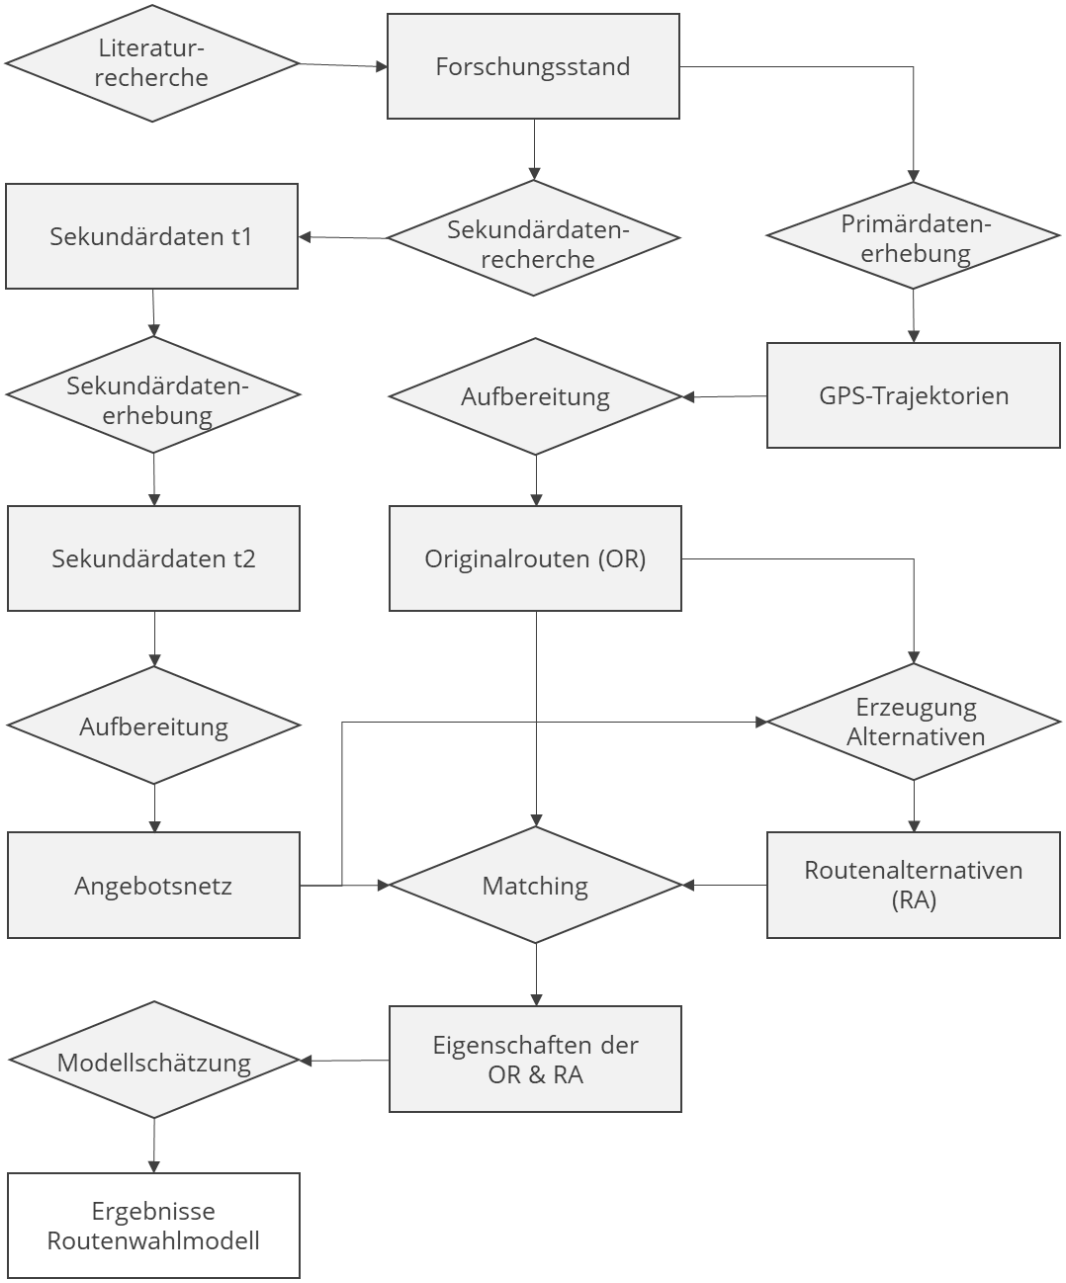


Abbildung 30: Ablaufschema der Methode

# 5. Ergebnisse

In diesem Kapitel werden die Ergebnisse der durchgeführten Arbeiten beschrieben. Um einen Überblick über die Stichprobeneigenschaften zu erhalten und die Ergebnisse in Kapitel 6 einordnen und diskutieren zu können, werden zunächst die Eigenschaften der Radfahrenden und der aufgezeichneten Fahrten vorgestellt (deskriptive Statistik). Anschließend erfolgt die Darstellung der multivariaten Analyseergebnisse (logistische Regression) zur Routenwahl.

## 5.1 Deskriptive Statistik

Innerhalb des Erhebungszeitraums haben in Dresden insgesamt 1.361 Radfahrende die STADTRADELN-App genutzt und ihre Fahrten aufgezeichnet. In dem Zeitraum wurden 25.730 GPS-Tracks übermittelt. Die Aufbereitung der hochgeladenen GPS-Daten führte schließlich zu einer Stichprobengröße von 18.459 Radfahrten mit einer zurückgelegten Gesamtstrecke von 86.507 km. Die genannte Fahrtenanzahl entspricht rund 71,7 % aller hochgeladenen Tracks und ist aufgrund der Datenaufbereitung notwendigerweise geringer als die Gesamtanzahl hochgeladener GPS-Tracks.

**Radfahrende**

Insgesamt haben 1.361 Proband*innen an der Datenerhebung teilgenommen. Etwas mehr als die Hälfte der Teilnehmenden waren Männer (n = 754). Der Frauenanteil der Stichprobe liegt bei knapp 40 % (n = 526). Rund 6 % der Teilnehmenden haben bei der Registrierung keine Angabe zum Geschlecht gemacht (n = 81). Die Geschlechterverteilung ist in Abbildung *31* dargestellt.

Der Anteil der durch Männer erbrachten Radfahrten an der Gesamtfahrtenanzahl beträgt ca. 59,2 % und liegt damit etwas über dem Männeranteil der Stichprobe (55,4 %). Demgegenüber liegt der Fahrtenanteil der Radfahrer*innen bei rund 36,3 % und fällt somit geringer aus als der Anteil der Frauen innerhalb der Stichprobe (38,6 %). Die Radfahrer in der Stichprobe nutzten folglich das Fahrrad vergleichsweise geringfügig häufiger als die Radfahrerinnen.

Rund 99 % der Proband*innen (n = 1.347) haben im Rahmen der Registrierung ein Geburtsjahr angegeben, aus dem jeweils das Alter berechnet wurde. Das Durchschnittsalter der Radfahrenden in der Stichprobe beträgt 34,5 Jahre (Mittel) bzw. 34,0 Jahre (Median). Die jüngsten Teilnehmenden waren elf Jahre alt. Die älteste Probandin war 77 Jahre alt. Dadurch ergibt sich eine Streuung des Alters von 66 Jahren. Die Standardabweichung

beträgt 10,5 Jahre. Die Altersverteilung der Stichprobe ist, in Anlehnung an die Altersklassen aus SrV (System repräsentativer Verkehrsbefragungen), detailliert in Abbildung 32 dargestellt.

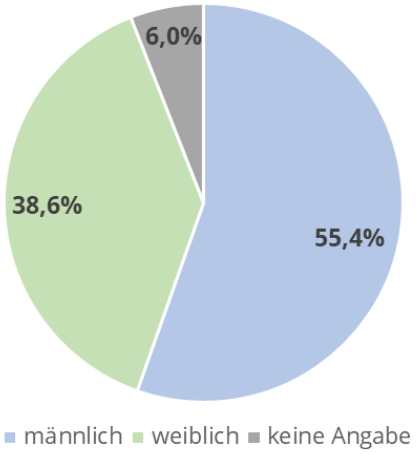


Abbildung 31: Geschlechterverteilung innerhalb der Stichprobe (n = 1.361)

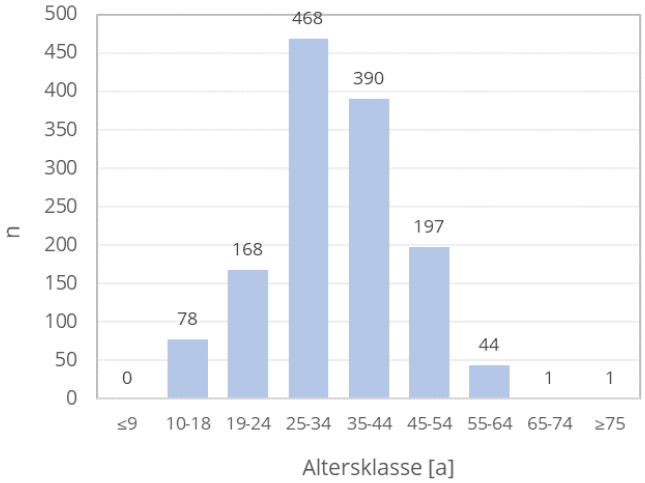


Abbildung 32: Altersverteilung innerhalb der Stichprobe (n = 1.347)

**Eigenschaften der Fahrten**

Bei den 18.459 im Datensatz vorliegenden Fahrten wurden insgesamt 86.507 km zurückgelegt. Angesichts der Gesamtlänge des in Dresden vorhandenen Radwegenetzes von ca. 420 km bzw. eines Straßennetzes von knapp 1.500 km (LH-Dresden-j 2020) kommt dies einer beträchtlichen Netzabdeckung gleich.

Abbildung 33 stellt die Summe der auf das Verkehrsnetz projizierten Fahrten – die Verkehrsmengen – dar und vermittelt einen Eindruck der Abdeckung des Dresdener Verkehrsnetzes. Aus der Abbildung wird deutlich, dass nahezu das gesamte innerstädtische Verkehrsnetz von den Radfahrenden genutzt wurde.

Die Fahrten sind dabei unterschiedlich auf die Elemente des Verkehrsnetzes verteilt. Stark frequentierte Streckenabschnitte befinden sich vor allem im Hauptverkehrsnetz und auf den Rad-Hauptrouten wie bspw. auf dem Elberadweg oder im Großen Garten (siehe Abbildung 33). Strecken im Nebennetz sind weniger stark frequentiert.

Die Fahrtweiten der zurückgelegten Routen sind sehr unterschiedlich ausgeprägt. Die durchschnittliche Fahrtweite der aufgezeichneten Routen beträgt 4,7 km (Mittelwert) bzw. 3,9 km (Median). Es wurden jedoch auch sehr kurze Fahrten (mindestens 300 m) sowie sehr lange Fahrten (maximal 28,5 km) zurückgelegt. Dies ergibt eine Streuung von 28,2 km. Abbildung 34 verdeutlicht die Fahrtweitenverteilung der aufgezeichneten Radfahrten.

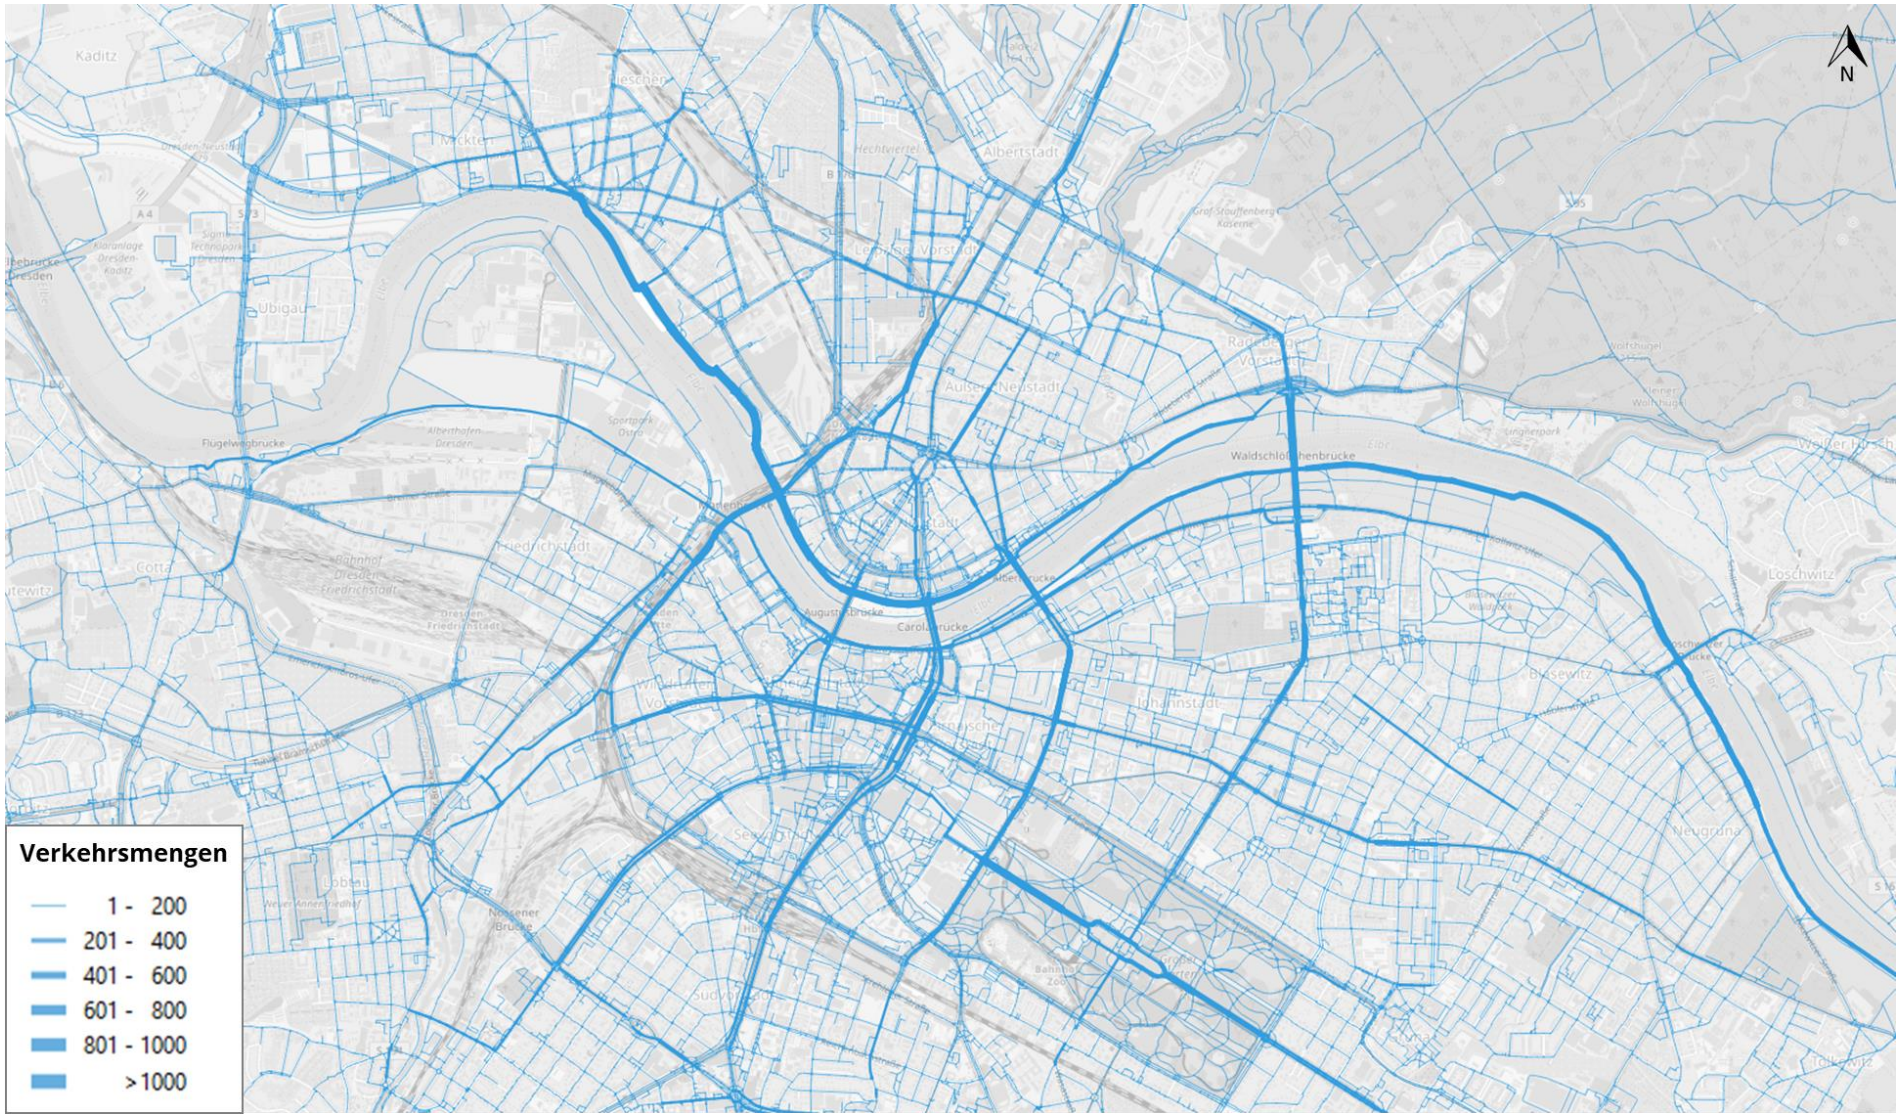


Abbildung 33: Netzabdeckung der Radfahrten in Dresden

Aus der dargestellten Fahrtweitenverteilung wird deutlich, dass die meisten Fahrten auf kurzen Distanzen zurückgelegt wurden. Am häufigsten wurden Fahrten mit einer Länge zwischen ein und zwei Kilometern zurückgelegt. Rund 60 % aller Fahrten sind kürzer als 5 km und fast 92 % aller Fahrten sind nicht länger als zehn Kilometer. Nur bei etwa 1,5 % aller Fahrten wird eine Fahrtweite von mehr als 15 km erreicht.

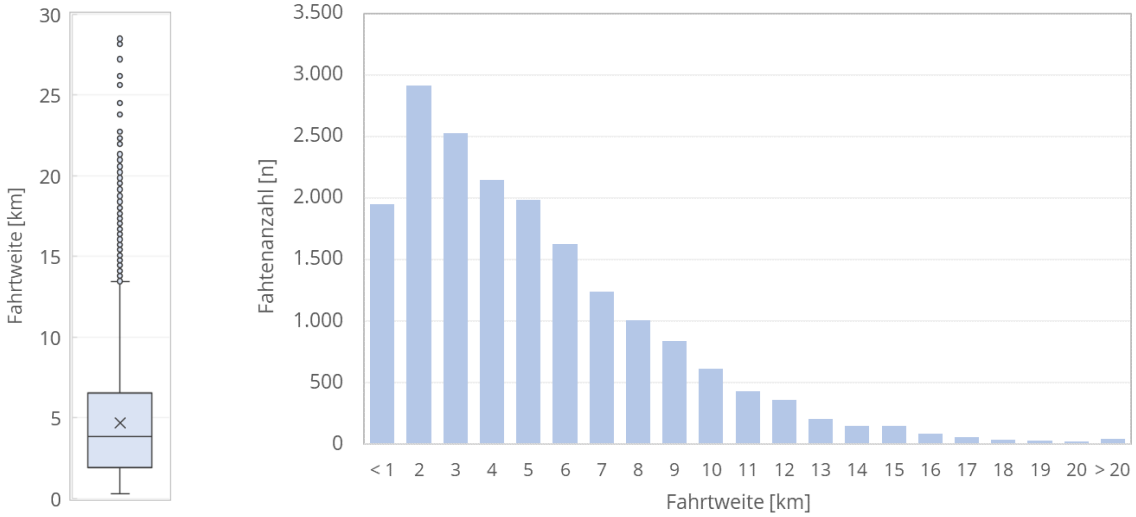


Abbildung 34: Boxplot (links) und Histogramm (rechts) der Fahrtweiten

Fahrten und Fahrtweiten weisen zudem geschlechterspezifische Unterschiede auf. Die Männer in der Stichprobe zeichneten insgesamt 10.936 Fahrten auf und legten dabei rund 54.222 km zurück. Die Radfahrerinnen zeichneten insgesamt 6.685 Fahrten auf und legten dabei etwa 28.184 km zurück. Damit ergibt sich eine durchschnittliche Fahrtweite von rund 4,2 km (Mittel) für Radfahrerinnen und 5,0 km (Mittel) für Radfahrer. Im Durschnitt ist die Fahrtweite der von Männern aufgezeichneten Fahrten rund 0,8 km (Mittelwert) länger als die durchschnittliche Fahrtweite der Frauen. Die Gruppe der Proband*innen, die keine Angaben zum Geschlecht machten, zeichneten insgesamt 832 Fahrten mit einer Gesamtlänge von ca. 4.087 km auf. Die Kennwerte aller Fahrten sowie ihre geschlechterspezifische Ausprägung können Tabelle 7 entnommen werden.

| | **Männer** | **Frauen** | **k.A.** | **insgesamt** |
|---|---|---|---|---|
| Minimum | 0,3 km | 0,3 km | 0,4 km | 0,3 km |
| Mittelwert | 5,0 km | 4,2 km | 4,9 km | 4,7 km |
| Median | 4,1 km | 3,5 km | 4,4 km | 3,9 km |
| Maximum | 28,5 km | 26,4 km | 18,7 km | 28,5 km |
| Streuung | 28,1 km | 26,1 km | 18,3 km | 28,2 km |
| Standardabweichung | 3,8 km | 3,1 km | 3,5 km | 3,6 km |

Tabelle 7: Kennwerte der Fahrtweiten

Die Betrachtung der Fahrtdauer zeigt, dass die durchschnittliche Fahrtzeit der Radfahrenden rund 15,1 Minuten (Mittelwert) bzw. 12,8 Minuten (Median) beträgt. Die geringste Fahrtdauer der Stichprobe beträgt rund eine Minute; es wurde eine maximale Fahrtdauer von rund 89 Minuten festgestellt. Die Fahrtdauer weist, analog zu den Fahrtweiten, eine hohe Streuung auf (88,0 Minuten).

Bei der Fahrtdauer sind nur sehr geringe geschlechterspezifische Unterschiede festzustellen. Im Durschnitt ist die Fahrtdauer von Fahrten männlicher Probanden rund 24 Sekunden (Mittelwert) bzw. 12 Sekunden (Median) länger als die durchschnittliche Fahrtdauer der durch Frauen aufgezeichneten Fahrten. Die entsprechenden Kennwerte aller Fahrten sowie ihre geschlechterspezifische Ausprägung sind in Tabelle *8* zusammengefasst. Abbildung *35* stellt die Verteilung der Fahrtweiten und Fahrtdauer grafisch dar.

| | **Männer** | **Frauen** | **k.A.** | **insgesamt** |
|---|---|---|---|---|
| Minimum | 0,9 Min. | 1,5 Min. | 1,5 Min. | 0,9 Min. |
| Mittelwert | 15,2 Min. | 14,8 Min. | 15,4 Min. | 15,0 Min. |
| Median | 12,9 Min. | 12,6 Min. | 14,5 Min. | 12,8 Min. |
| Maximum | 89,0 Min. | 74,8 Min. | 87,4 Min. | 89,0 Min. |
| Streuung | 88,0 Min. | 73,3 Min. | 85,9 Min. | 88,0 Min. |
| Standardabweichung | 10,9 Min. | 10,3 Min. | 10,2 Min. | 10,7 Min. |

Tabelle 8: Kennwerte der Fahrtdauer

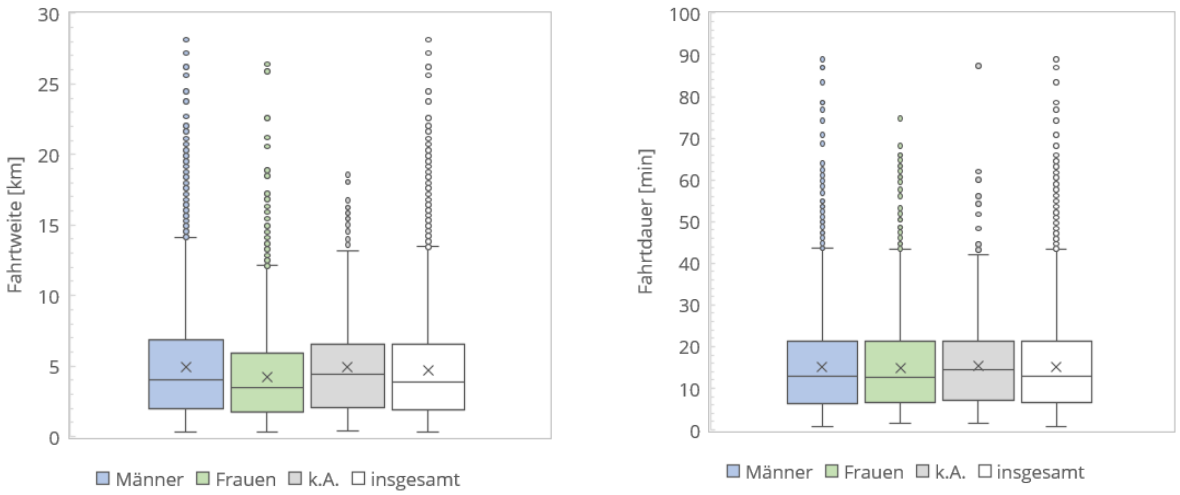


Abbildung 35: Verteilung der Fahrtweiten und Fahrtdauer

Die durchschnittliche Geschwindigkeit der aufgezeichneten Fahrten beträgt rund 18,5 km/h (Mittelwert) bzw. 18,3 km/h (Median). Die geringste gemessene Geschwindigkeit der Stichprobe beträgt rund 6 km/h. Demgegenüber wurde eine maximale Fahrtgeschwindigkeit von rund 37,9 km/h erreicht. Es wird deutlich, dass die Geschwindigkeit mit ca. 32 km/h eine sehr hohe Streuung aufweist.

Die Betrachtung der Geschwindigkeiten zeigt zudem leichte geschlechterspezifische Unterschiede auf. Im Durschnitt beträgt die Geschwindigkeit bei den Fahrten der Radfahrer rund 19,4 km/h (Mittelwert und Median). Bei den von Radfahrerinnen aufgezeichneten Fahrten beträgt die durchschnittliche Geschwindigkeit ca. 17,0 km/h (Mittelwert) bzw. 16,8 km/h (Median). Die Unterschiede sind bei den minimalen und maximalen Geschwindigkeiten nicht ganz so deutlich ausgeprägt. Die entsprechenden Kennwerte sind in Tabelle *9* zusammengefasst.

| | **Männer** | **Frauen** | **k.A.** | **insgesamt** |
|---|---|---|---|---|
| Minimum | 6,0 km/h | 6,1 km/h | 9,2 km/h | 6,0 km/h |
| Mittelwert | 19,4 km/h | 17,0 km/h | 18,9 km/h | 18,5 km/h |
| Median | 19,4 km/h | 16,8 km/h | 18,5 km/h | 18,3 km/h |
| Maximum | 37,9 km/h | 34,7 km/h | 33,2 km/h | 37,9 km/h |
| Streuung | 32,0 km/h | 28,6 km/h | 24,0 km/h | 32,0 km/h |
| Standardabweichung | 4,0 km/h | 3,3 km/h | 4,1 km/h | 4,0 km/h |

Tabelle 9: Kennwerte der Geschwindigkeiten

**Eigenschaften der Routen**

Im Folgenden werden die Eigenschaften der gewählten Routen beschrieben. Darüber hinaus werden sie den Eigenschaften der nicht gewählten Routenalternativen gegenübergestellt, um eine erste Einschätzung bzgl. der Routeneigenschaften und der Wahl von Routen ableiten zu können. Da nicht alle in Kapitel 4.2.2 beschriebenen Attribute in die Analyse einbezogen werden konnten (siehe Kapitel 4.3.1), basiert die deskriptive Auswertung der Routeneigenschaften maßgeblich auf den in Kapitel 4.3.1 beschriebenen Variablen.

***a) Distanzen/Fahrtweiten***

Der Vergleich der Fahrtweitenverteilung zeigt auf, dass die gewählten Routen im Durchschnitt ein wenig kürzer sind als die nicht gewählten Alternativen. Während die durchschnittliche Distanz der gewählten Routen 4,7 km (Mittelwert) bzw. 3,9 km (Median) beträgt, liegt die durchschnittliche Distanz der nicht gewählten Alternativen bei 4,9 km (Mittelwert) bzw. 4,3 km (Median). Leichte Unterschiede sind ebenso bei den minimalen und maximalen Fahrtweiten sowie der resultierenden Streuung zu beobachten (siehe Tabelle *10*).

Abbildung *36* stellt die Fahrtweitenverteilung grafisch dar. Das Boxplot-Diagramm (links) verdeutlicht in Analogie zur Tabelle *10*, dass die gewählten Routen gegenüber den Alternativen eine etwas höhere Streuung sowie einen leicht höheren Mittelwert/Median der Fahrtweiten aufweisen, ansonsten jedoch ähnlich verteilt sind.

| | Routen | Alternativen |
|---|---|---|
| Minimum | 0,3 km | 0,3 km |
| Mittelwert | 4,7 km | 4,9 km |
| Median | 3,9 km | 4,3 km |
| Maximum | 28,5 km | 27,6 km |
| Streuung | 28,2 km | 27,3 km |
| Standardabweichung | 3,6 km | 3,3 km |

Tabelle 10: Kennwerte der Fahrtweiten der Routen und ihrer Alternativen

Die Verteilung der absoluten Häufigkeit in Entfernungsklassen (Abbildung 36, rechts) zeigt hingegen, dass die Verteilung der Fahrtweiten der Routen und Alternativen leicht unterschiedlich ausfällt. Bei den gewählten Routen sind deutlich mehr Fahrten bis drei Kilometer Länge zu beobachten – bei längeren Fahrten kehrt sich das Verhältnis um. Dies lässt zunächst darauf schließen, dass die Proband*innen auf Relationen mit geringeren räumlichen Distanzen eher direkte und kurze Routen gewählt haben.

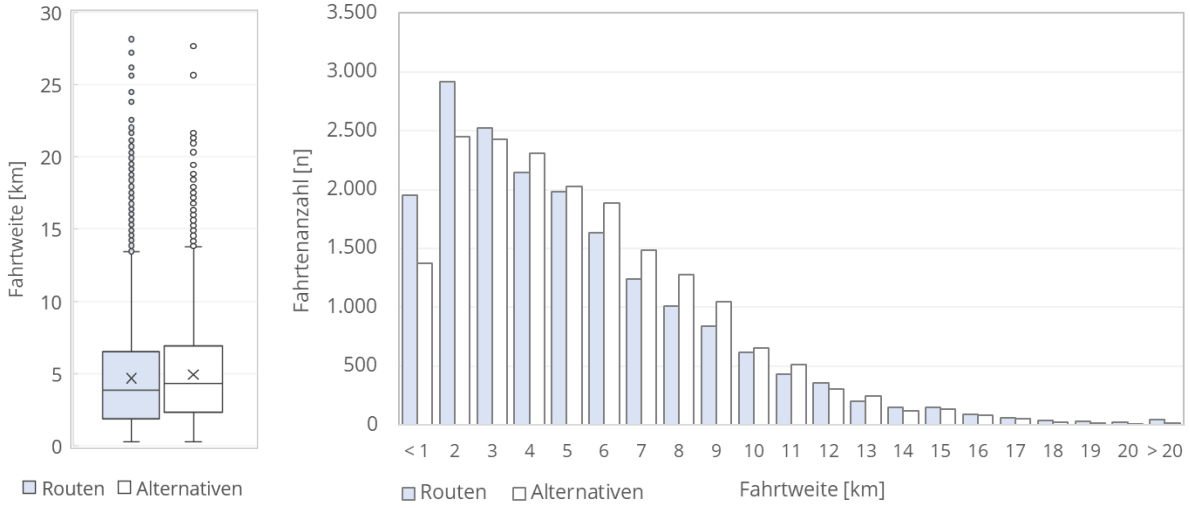


Abbildung 36: Boxplot (links) und Histogramm (rechts) der Fahrtweiten der Routen und ihrer Alternativen

Aus den Daten ergibt sich der Eindruck, dass die Proband*innen eher kürzere Routen wählten. Dies könnte auf eine Distanzempfindlichkeit bei der Routenwahl hindeuten. Für kausale Zusammenhänge wird auf die Ergebnisse der multivariaten Analyse (siehe Kapitel 5.2) verwiesen.

### *b) Längsneigung*

Auf den gewählten Routen beträgt die maximale Längsneigung, die die Radfahrenden auf einem Teilabschnitt entlang einer Route zu überwinden hatten, im Durchschnitt rund 6,86 % (Mittelwert) bzw. 5,37 % (Median). Auf mehr als 46 % aller Routen ist die maximale Längsneigung auf einem Streckenabschnitt nicht größer als 5 % und mehr als 80 % aller

Routen weisen eine maximale Längsneigung entlang der Route von maximal 10 % auf. Es existieren zudem Routen, deren maximale Längsneigung gleich Null ist – die also keine Steigungen entlang ihrer Route aufweisen (Minimum = 0,0 %). Es konnte eine maximale Längsneigung von Streckenabschnitten von rund 59,7 % beobachtet werden. Es handelt sich dabei jedoch um Einzelfälle (99,9 % aller Werte übersteigen eine max. Längsneigung von 45 % nicht).

Die nicht gewählten Alternativen weisen durchschnittlich leicht höhere Werte auf. Im Durchschnitt beträgt die maximale Längsneigung 9,27 % (Mittelwert) bzw. 6,98 % (Median). Die Alternativrouten enthalten zwar ebenso Routen, die keine Längsneigungen aufweisen (Minimum = 0,0 %), sie weisen jedoch etwas höhere Maximalwerte (60,6 %) auf. Abbildung *37* visualisiert die Verteilung der maximalen Längsneigung über alle Routen und Alternativen. Die Kennwerte zur maximalen Längsneigung sind in Tabelle *11* gegenübergestellt.

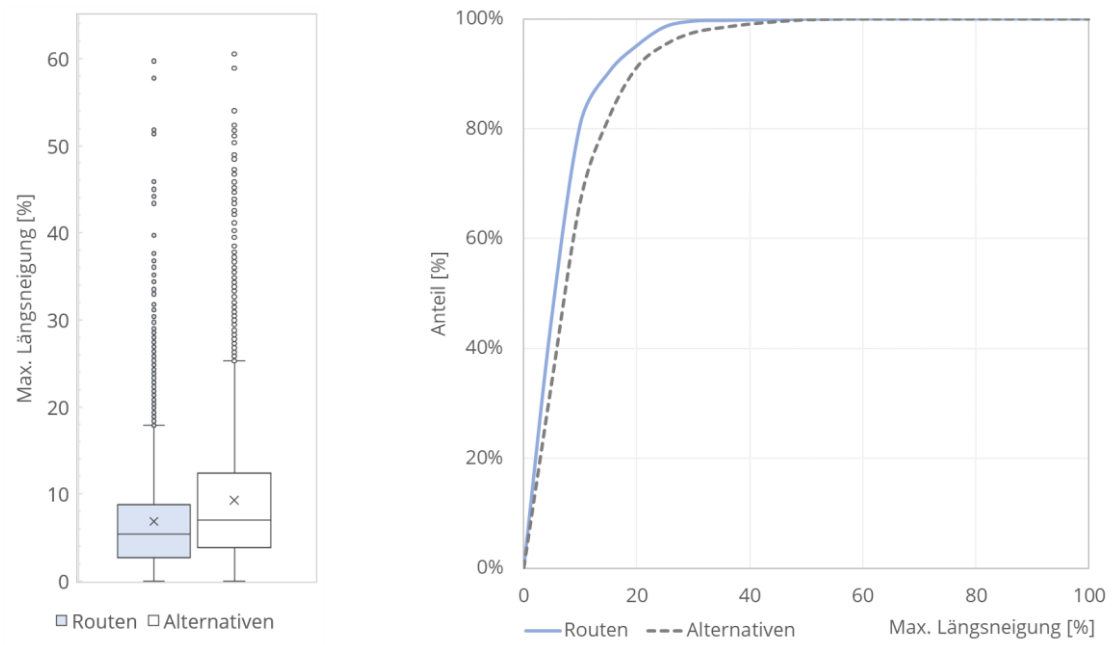


Abbildung 37: Boxplot (links) und Verteilung (rechts) der max. Längsneigung der Routen und Alternativen

Aus den Kennzahlen lässt sich resümieren, dass die gewählten Routen im Durchschnitt geringere maximale Längsneigungen auf Streckenabschnitten entlang der Route aufweisen. Die Radfahrenden wählten folglich eher Routen, auf denen die maximal vorhandene Längsneigung geringer ausfiel.

| | Routen | Alternativen |
|---|---|---|
| Minimum | 0,00 % | 0,00 % |
| Mittelwert | 6,86 % | 9,27 % |
| Median | 5,37 % | 6,98 % |
| Maximum | 59,71 % | 60,55 % |
| Streuung | 59,71 % | 60,55 % |
| Standardabweichung | 5,89 % | 7,76 % |

Tabelle 11: Kennwerte zur max. Längsneigung der Routen und ihrer Alternativen

Die Betrachtung der Längsneigung nach Längsneigungs-Klassen zeigt leichte Unterschiede bei den durchschnittlichen Anteilen entlang der Routen und Alternativen. Es fällt auf, dass die durchschnittlichen Anteile von Streckenabschnitten mit höheren Längsneigungen auf den gewählten Routen geringer ausfallen. So liegt der Anteil von Strecken mit einer Längsneigung von mehr als 2 % entlang der Routen im Mittel bei ca. 7,5 %. Auf den Alternativrouten besitzen im Mittel rund 8,8 % der Strecken eine Längsneigung von mehr als 2 %. Im Gegensatz dazu sind die Anteile von Strecken mit geringeren Längsneigungen im Mittel leicht erhöht (siehe Abbildung *38*).

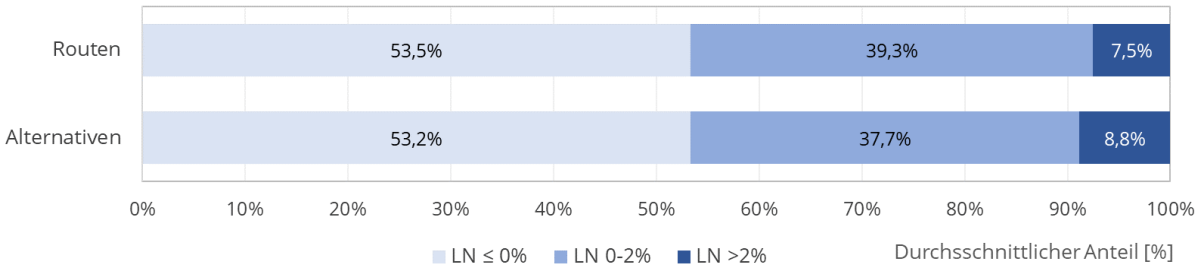


Abbildung 38: Durchschnittliche Anteile der Längsneigungsklassen entlang der Routen und Alternativen

Es lässt sich zusammenfassen, dass die gewählten Routen im Durchschnitt geringere Längsneigungen von Streckenabschnitten entlang der Route aufweisen als die nicht gewählten Alternativen. Die Unterschiede treten bei der maximalen Längsneigung besonders deutlich hervor. Dies könnte auf eine Präferenz der Radfahrenden hinweisen, auf Relationen, bei denen Höhenunterschiede überwunden werden müssen, Routen mit geringen Längsneigungen zu bevorzugen.

### *c) Radverkehrsführungsform*

Die Existenz von Radverkehrsinfrastruktur bzw. markierten Radwegen (aggregierte Variable – siehe Kapitel 4.3.1) scheint einen wesentlichen Einfluss auf die Wahl einer Route auszuüben. Entlang der gewählten Routen liegen die durchschnittlichen Anteile der Strecken, die über eine Radverkehrsinfrastruktur oder markierte Schutz- und Radfahrstreifen verfügen, deutlich über denen der nicht gewählten Alternativen (siehe Abbildung *39*).

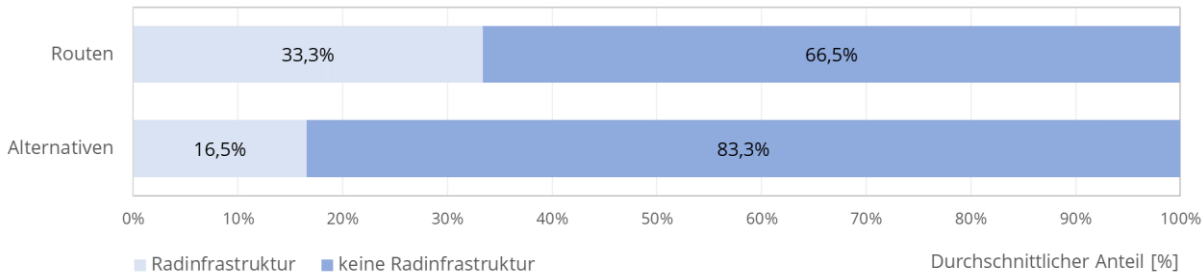


Abbildung 39: Durchschnittliche Anteile der Führungsform der Routen und Alternativen

Auf den gewählten Routen waren die Radfahrenden im Mittel zu rund 33,3 % (Mittelwert) bzw. 34,4 % (Median) auf Strecken unterwegs, auf denen Radverkehrsinfrastruktur bzw. markierte Radwege vorhanden waren. Der Anteil ist bei den nicht gewählten Alternativen mit rund 16,5 % (Mittelwert) bzw. 14,3 % (Median) nur etwa halb so groß. Die durchschnittlichen Anteile von Streckenabschnitten ohne Radverkehrsinfrastruktur bzw. markierte Radwege fallen entlang der genutzten Routen mit 66,5 % (Mittelwert) bzw. 65,5 % (Median) entsprechend geringer aus als entlang der Routenalternativen (83,3 % bzw. 85,5 %).

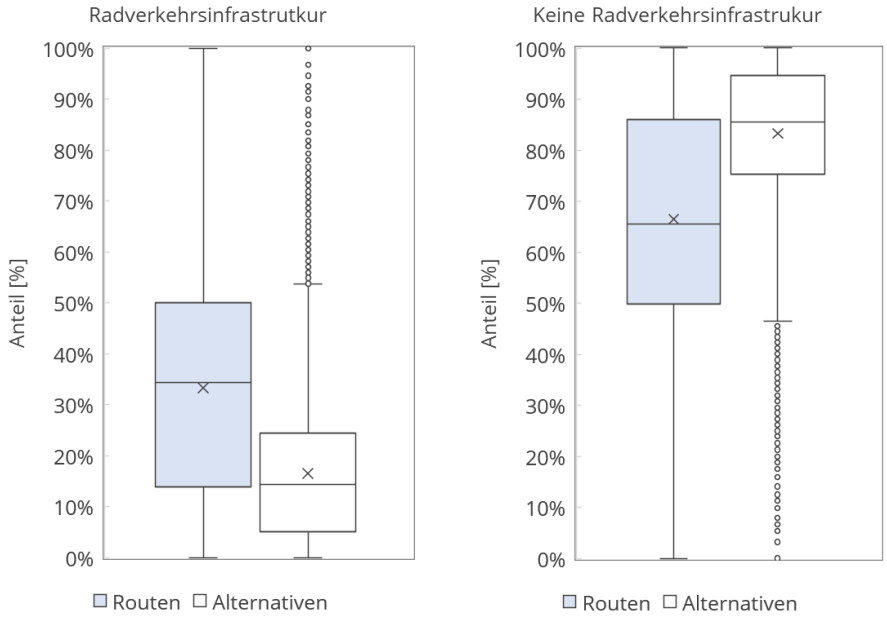


Abbildung 40: Verteilung der Anteile mit (links) und ohne (rechts) Radverkehrsinfrastruktur entlang der Routen und Alternativen

Abbildung *40* verdeutlicht die Streuung der Anteile für die Routen und Alternativen und unterstreicht die Tendenz zur Nutzung von Radverkehrsinfrastruktur durch die Radfahrenden. Es wird jedoch auch deutlich, dass sowohl Routen als auch Alternativen existieren, bei denen keine Radverkehrsinfrastruktur bzw. keine markierten Radwege vorhanden sind (minimaler Anteil jeweils 0 %). Es konnten jedoch auch Routen und Alternativen

beobachtet werden, auf denen durchgängig Radverkehrsinfrastruktur bzw. markierte Radwege vorhanden sind (Maximum jeweils 100 %).

Auch wenn aus den Ergebnissen der deskriptiven Analyse keine Kausalitäten abgeleitet werden können, so deuten die Ergebnisse dennoch auf einen Zusammenhang zwischen der Führungsform und der Routenwahl hin, weil die gewählten Routen deutlich höhere Anteile entsprechender Radverkehrsinfrastruktur beinhalten.

#### *d) Breite der Radverkehrsführung*

Zur Breite der Radverkehrsführung lagen im initialen Datensatz vergleichsweise wenig Informationen vor, sodass auch diese aggregiert wurden (siehe Kapitel 4.3.1). Die Breite der Radverkehrsführung scheint einen wesentlichen Einfluss auf die Wahl einer Route auszuüben. So ist der durchschnittliche Anteil von Streckenabschnitten mit einer Breite der Radverkehrsführung von weniger als 1,5 m entlang der gewählten Routen deutlich geringer als auf den nicht gewählten Alternativen (siehe Abbildung *41*).

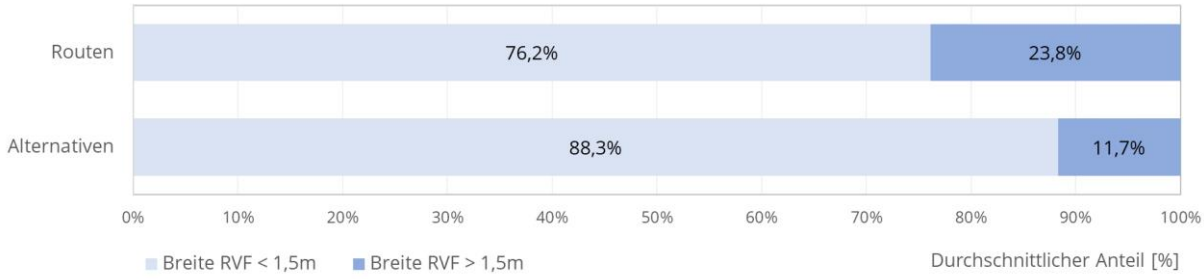


Abbildung 41: Durchschnittliche Anteile der Breite der Radverkehrsführung (RVF) entlang der Routen und Alternativen

Auf den gewählten Routen waren die Radfahrenden im Mittel zu rund 76,2 % (Mittelwert) bzw. 78,5 % (Median) auf Strecken unterwegs, auf denen die Breite der Radverkehrsführung kleiner als 1,5 m ist. Der Anteil liegt bei den nicht gewählten Alternativen mit rund 88,3 % (Mittelwert) bzw. 91,0 % (Median) deutlich höher. Die durchschnittlichen Anteile von Streckenabschnitten mit einer Breite der Radverkehrsführung von mehr als 1,5 m fallen entlang der genutzten Routen mit 23,8 % (Mittelwert) bzw. 21,5 % (Median) entsprechend höher aus als entlang der Routenalternativen (11,7 % bzw. 9,0 %). Abbildung *42* verdeutlicht die Streuung der Anteile für die Routen und deren Alternativen und unterstreicht die Tendenz zur Nutzung von Routen mit einer größeren Breite der Radverkehrsführung.

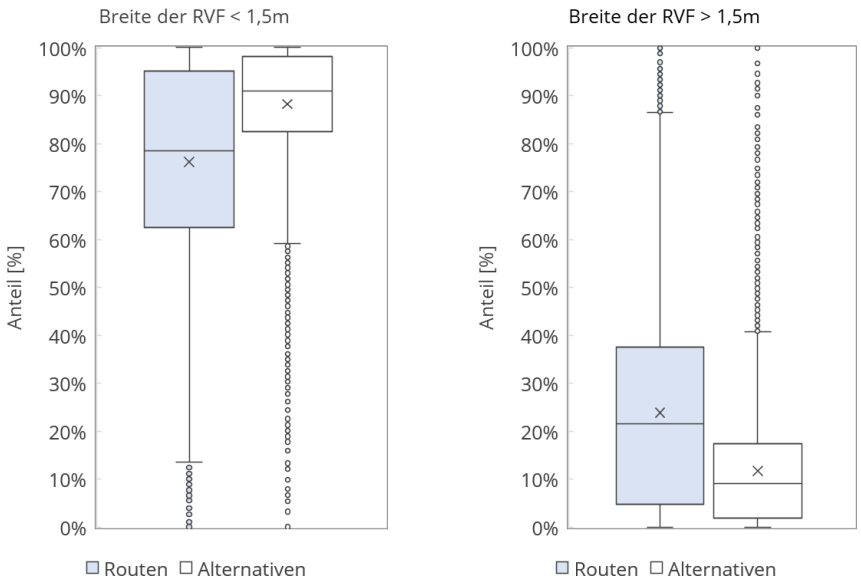


Abbildung 42: Verteilung der Breite der Radverkehrsführung (RVF) entlang der Routen und Alternativen

Darüber hinaus wird deutlich, dass sowohl Routen als auch Alternativen existieren, entlang derer die Breite der Führung durchgängig unter 1,5 m (min. Anteil jeweils 0 %) oder über 1,5 m liegt (Maximum jeweils 100 %). Es ist jedoch anzumerken, dass diese Fälle weniger häufig zu beobachten sind als die erstgenannten.

Die Ergebnisse der deskriptiven Auswertung deuten auf einen Zusammenhang zwischen der Breite der Radverkehrsführung und der Routenwahl hin. Die unterschiedlich hohen Anteile der verschiedenen Breiten entlang der Routen und Alternativen können als Indiz gedeutet werden, dass die Radfahrenden die Nutzung von breiteren Führungsformen präferieren.

#### *e) Oberflächenbeschaffenheit*

Die Oberflächenqualität unterscheidet sich stark zwischen den gewählten Routen und den nicht gewählten Alternativen. Entlang der gewählten Routen besitzen mit 53,7 % (Mittelwert) bzw. 56,2 % (Median) im Durchschnitt deutlich mehr Streckenabschnitte eine asphaltierte Oberfläche als entlang der nicht gewählten Alternativen, deren durchschnittlicher Anteil bei rund 37,8 % (Mittelwert und Median) liegt. Es existieren sowohl Routen als auch Alternativen, deren Oberfläche zu 100 % (Max.) oder 0 % (Min.) über eine Asphaltdecke verfügen. Der Vergleich der mittleren Anteile sowie der in Abbildung *43* (links) dargestellten Verteilung der Merkmalsausprägungen verdeutlicht jedoch, dass sich die von den Radfahrenden gewählten Wege bzgl. der Oberflächenbeschaffenheit insgesamt stark unterscheiden.

Aussagen zu den durchschnittlichen Anteilen von Streckenabschnitten des Oberflächentyps „Kopfsteinpflaster“ lassen sich aus den vorhandenen Daten (siehe Kapitel 4.3.1)

nur schwer ableiten. Es kann grundlegend festgehalten werden, dass die gewählten Routen mit einem durchschnittlichen Anteil von rund 2,0 % über weniger Streckenabschnitte mit Kopfsteinpflaster verfügen, als die nicht gewählten Alternativen (3,2 %). Dass die Zahlen jedoch wenig Aussagekraft besitzen, wird bei der Betrachtung des Medians (für beide 0,0 %) sowie der Verteilung der Merkmalsausprägung „Kopfsteinpflaster“ deutlich (siehe Abbildung *43*, rechts). Unterschiede zwischen Routen und Alternativen oder eindeutige Tendenzen sind dem Boxplot kaum zu entnehmen.

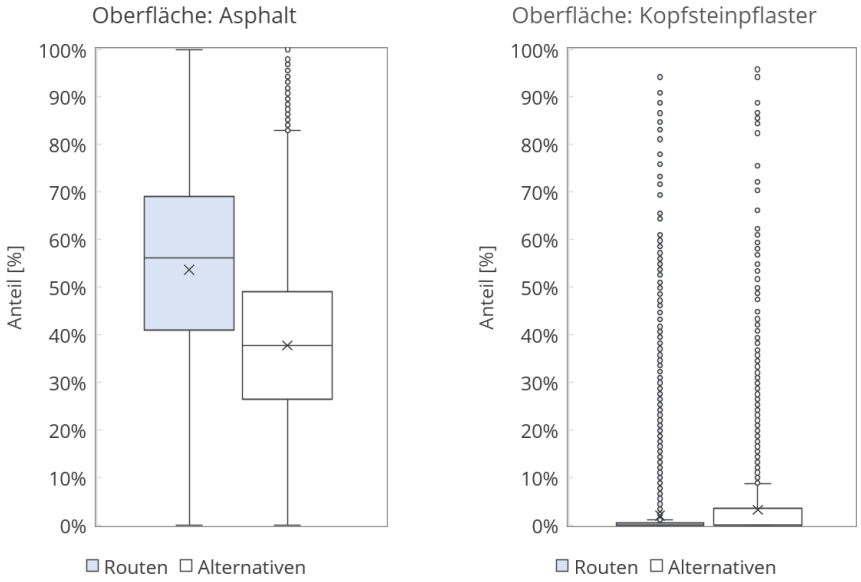


Abbildung 43: Verteilung der Oberflächentypen „Asphalt“ und „Kopfsteinpflaster“ entlang der Routen und Alternativen

Ursachen der Verteilung der Merkmalsausprägung könnten zum einen in den recht hohen Anteilen fehlender Informationen begründet sein (siehe Abbildung *44*), als auch in der Tatsache, dass die Ausprägung „Kopfsteinpflaster“ der Variable „Oberflächentyp“ im Angebotsnetz nicht häufig vorkommt.

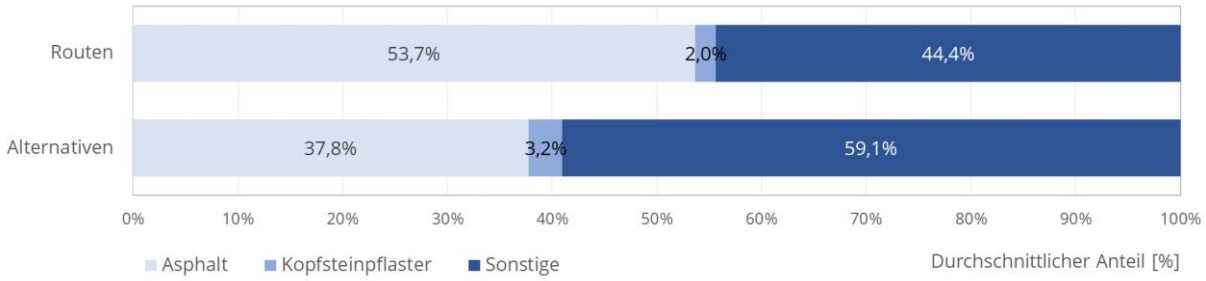


Abbildung 44: Durchschnittliche Anteile der Oberflächentypen entlang der Routen und Alternativen

Die Ergebnisse der deskriptiven Auswertung ergeben für die vorliegende Variable ein plausibles, aber noch nicht vollständiges Bild. Routen mit einer guten Oberflächenqualität (Asphalt) wurden bei der Wahl der Route offensichtlich bevorzugt.

### *f) Radverkehrsstärken*

Bei der Betrachtung der Radverkehrsstärken sind ebenfalls deutliche Unterschiede zwischen den gewählten Routen und den nicht gewählten Alternativen zu beobachten. Entlang der gewählten Routen liegt der durchschnittliche $DTV_{Rad}$ bei rund 942 Radfahrenden/Tag (Mittelwert) bzw. 793 Radfahrenden/Tag (Median). Entlang der Alternativen liegt er hingegen bei knapp 411 Radfahrenden/Tag (Mittelwert) bzw. 328 Radfahrenden/Tag (Median). Die Radverkehrsstärke ist entlang der gewählten Routen im Mittel demnach mehr als doppelt so hoch wie entlang der Alternativen. Die gewählten Routen zeigen darüber hinaus höhere Maximalwerte der durchschnittlichen Radverkehrsstärke (max. 6.081 Radfahrende/Tag) im Vergleich mit den Alternativen (max. 4.225 Radfahrende/Tag) und besitzen dementsprechend auch eine breitere Streuung (siehe Abbildung *45*, links).

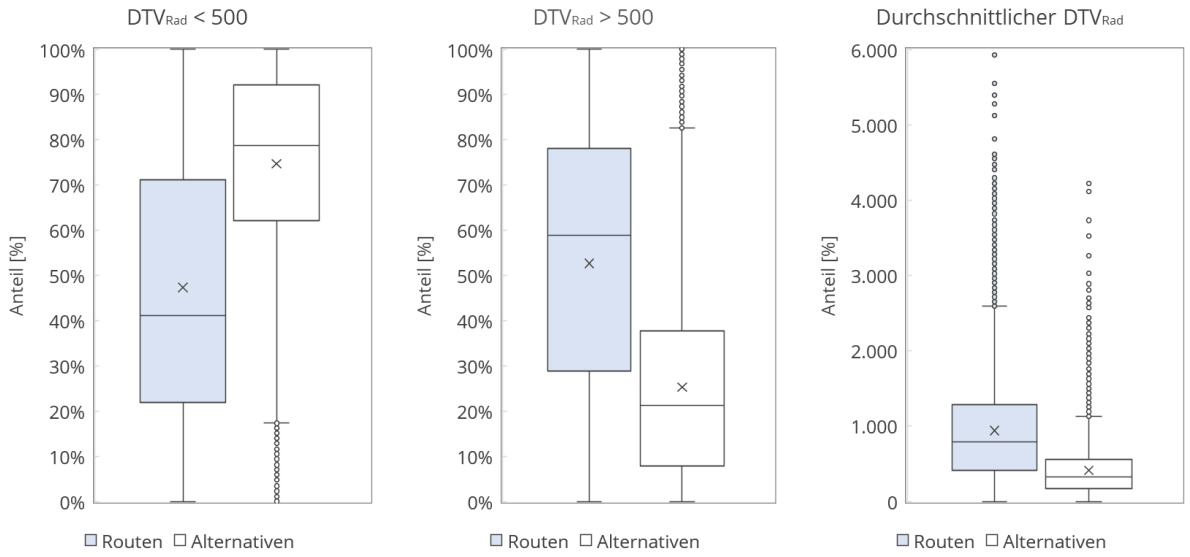


Abbildung 45: Durchschnittlich tägliche Radverkehrsstärke (DTV-Rad) entlang der Routen und Alternativen

Die Betrachtung der Radverkehrsstärken nach den aggregierten Klassen zeigt, dass auf den gewählten Routen deutlich mehr Radfahrende unterwegs waren als auf den nicht gewählten Alternativen. So waren die Radfahrenden auf den gewählten Routen im Durchschnitt zu rund 47,3 % auf Streckenabschnitten unterwegs, auf denen die Radverkehrsstärke ≤ 500 Radfahrende/Tag war. Dieser Anteil liegt bei den Routenalternativen mit einem Wert von rund 74,7 % deutlich höher. Im Mittel verliefen etwa 52,7 % der gewählten Routen auf Streckenabschnitten mit einem $DTV_{Rad}$ > 500 Radfahrende/Tag. Dieser Anteil fällt bei den nicht gewählten Alternativen mit 25,3 % deutlich geringer aus. Die durchschnittlichen Anteile sind in Abbildung *46* gegenübergestellt. Die Streuung sowie die Extremwerte (Minima und Maxima) können Abbildung *45* entnommen werden.

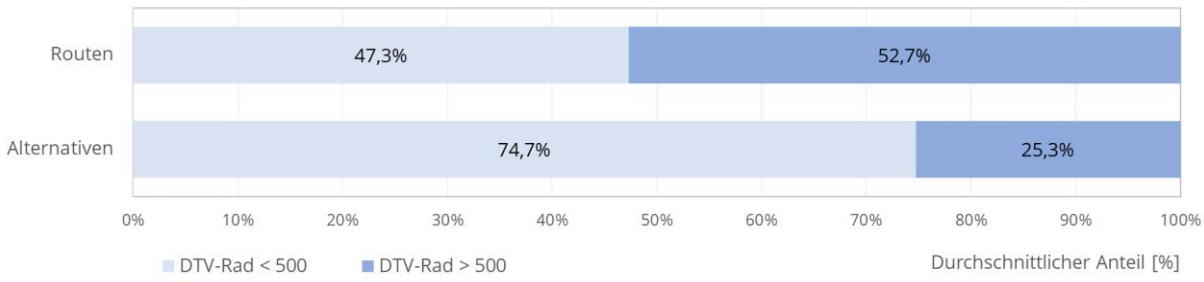


Abbildung 46: Durchschnittliche Anteile der Radverkehrsstärken-Klassen entlang der Routen und Alternativen

Es lässt sich zusammenfassen, dass entlang der gewählten Routen im Mittel deutlich mehr Radfahrende unterwegs waren als auf den nicht gewählten Alternativen. Dies könnte auf eine Präferenz der Radfahrenden hinweisen, Routen mit mehr Radverkehr zu bevorzugen.

### *g) Kraftfahrzeugverkehrsstärke*

Mit ca. 7.507 Kfz/Tag (Mittelwert) bzw. 6.842 Kfz/Tag (Median) ist im Durchschnitt eine höhere Kraftfahrzeugverkehrsstärke entlang der gewählten Routen zu beobachten als entlang der nicht gewählten Alternativen. Bei diesen beträgt der $DTV_{Kfz}$ im Durchschnitt ca. 6.981 Kfz/Tag (Mittelwert) bzw. 6.372 Kfz/Tag (Median). Aus den Werten ergibt sich eine Differenz von 526 Kfz/Tag (Mittelwert) bzw. 469 Kfz/Tag (Median). Dies entspricht einer relativen Abweichung von jeweils rund 7 %. Die Unterschiede sind also nicht so deutlich ausgeprägt wie bei den bisher betrachteten Variablen. Weitere Kennwerte zur durchschnittlichen Kraftfahrzeugverkehrsstärke entlang der Routen und Alternativen sind in Tabelle *12* gegenübergestellt. Die Verteilung der Werte ist in Abbildung *47* visualisiert.

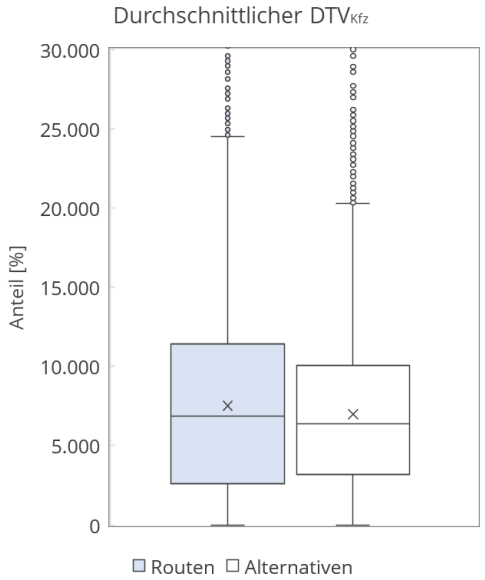


Abbildung 47: $DTV_{Kfz}$ entlang der Routen und deren Alternativen

| | Routen | Alternativen |
|---|---|---|
| Minimum | - | - |
| Mittelwert | 7.507 Kfz | 6.981 Kfz |
| Median | 6.842 Kfz | 6.372 Kfz |
| Maximum | 37.352 Kfz | 42.100 Kfz |
| Streuung | 37.352 Kfz | 42.100 Kfz |
| Standardabw. | 5.721 Kfz | 4.893 Kfz |

Tabelle 12: Kennwerte der mittleren Kraftfahrzeugverkehrsstärke entlang der Routen und Alternativen

Die Betrachtung des mittleren $DTV_{Kfz}$ entlang der Routen und Alternativen zeigt zunächst auf, dass entlang der gewählten Routen mehr motorisierter Verkehr vorhanden war. Die deskriptive Auswertung zeigt jedoch ebenso, dass die Unterschiede zwischen den von den Radfahrenden gewählten Routen und den nicht gewählten Alternativen nicht sonderlich stark ausgeprägt sind. Ob sich ein vergleichsweise höherer $DTV_{Kfz}$ tatsächlich positiv auf die Wahl einer Route auswirkt und inwiefern ein Zusammenhang zwischen den Verkehrsstärken des motorisierten Verkehrs und den Präferenzen der Routenwahl besteht, offenbart die multivariate Analyse (siehe Kapitel 5.2).

### *h) Fahrstreifenanzahl*

Die Betrachtung der Fahrstreifenanzahl des motorisierten Verkehrs (MV) erzeugt ein differenziertes Bild, das bei der Betrachtung der beiden vorhandenen Variablen („1 Fahrstreifen“ und „>1 Fahrstreifen“) intuitiv nicht direkt erklärbar scheint. Es lässt sich zunächst festhalten, dass der durchschnittliche Anteil von Streckenabschnitten mit nur einem Fahrstreifen (FS) für den motorisierten Verkehr entlang der gewählten Routen höher ausfällt, als auf den nicht gewählten Alternativen.

Auf den gewählten Routen waren die Radfahrenden im Mittel zu 40,1 % (Mittelwert) bzw. 39,3 % (Median) auf Strecken unterwegs, auf denen für den MV nur ein Fahrstreifen zur Verfügung steht. Dieser Anteil ist entlang der nicht gewählten Alternativen mit rund 35,2 % (Mittelwert) bzw. 35,0 % (Median) deutlich kleiner.

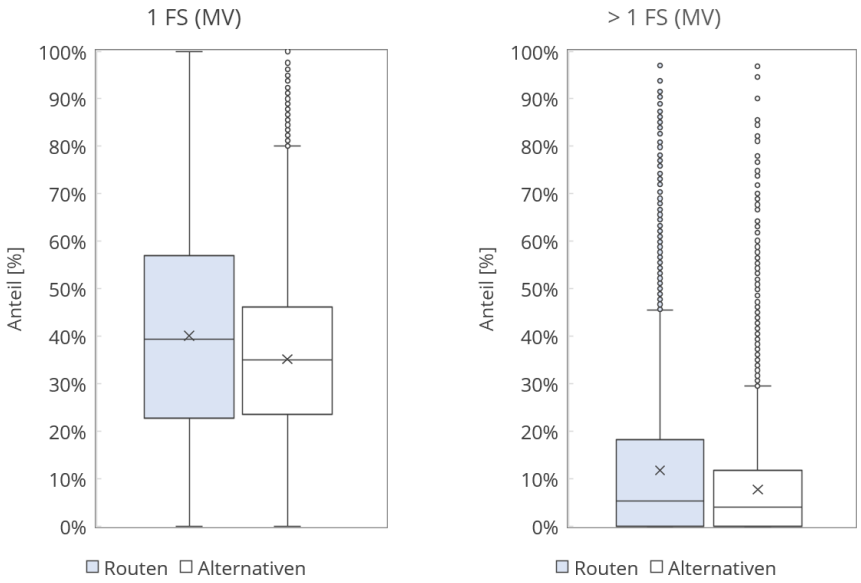


Abbildung 48: Verteilung der Fahrstreifenanzahl (FS) entlang der Routen und Alternativen

Es existieren sowohl Routen als auch Alternativen, entlang derer nur ein Fahrstreifen für den MV vorhanden ist (Max = 100 %). Die gleiche Aussage kann für Routen getätigt werden, entlang derer der Anteil von Strecken mit einem Fahrstreifen gleich Null ist

(Min = 0 %). Die Betrachtung der Verteilung (siehe Abbildung *48*, links) verdeutlicht, dass die Variable entlang der Alternativen eine geringere Streuung aufweist und entlang der Routen gleichmäßiger verteilt ist.

Die durchschnittlichen Anteile von Streckenabschnitten mit mehr als einem Fahrstreifen für den MV betragen entlang der genutzten Routen 11,7 % (Mittelwert) bzw. 5,2 % (Median). Auch diese Werte fallen mit 7,7 % (Mittelwert) bzw. 3,9 % (Median) entlang der Routenalternativen geringer aus. Abbildung *48* (rechts) verdeutlicht die Streuung der Anteile für die einzelnen Routen und Alternativen und deutet eine Tendenz zur Nutzung von Routen mit mehr als einem Fahrstreifen für den MV an. Die Unterschiede sind jedoch sehr marginal und die Verteilung der Merkmalsausprägungen ist aufgrund der hohen Anteile fehlender Informationen (siehe Abbildung *49*) schwer zu interpretieren.

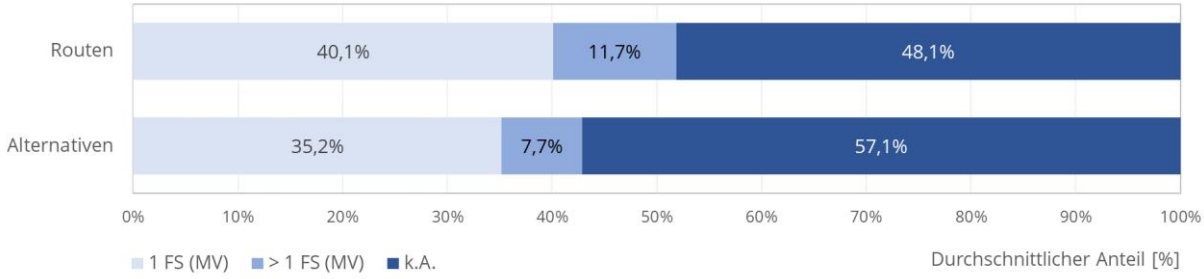


Abbildung 49: Durchschnittliche Anteile der Fahrstreifenanzahl (FS) entlang der Routen und Alternativen

Die Ergebnisse der deskriptiven Auswertung ergeben für die vorliegende Variable auf den ersten Blick ein relativ eindeutiges Bild. Es lassen sich jedoch erst aus der Kombination mit anderen Aussagen zum Einfluss der Variable und zu den Kausalitäten tätigen (siehe Kapitel 5.2).

#### *i) Zulässige Höchstgeschwindigkeit des Kfz-Verkehrs*

Die Betrachtung der maximal zulässigen Höchstgeschwindigkeiten des motorisierten Verkehrs entlang der Routen und Alternativ erzeugt ebenfalls ein Bild, das mit bloßem Blick auf die Anteile der vorhandenen Variablen nicht intuitiv erklärbar scheint. Entlang der gewählten Routen fällt der Streckenanteil der Routen, auf denen für den MV eine maximal zulässige Geschwindigkeit von ≤ 30 km/h gilt, im Durchschnitt geringer aus als auf den nicht gewählten Alternativen. Das Verhältnis dreht sich bei der Betrachtung von Streckenabschnitten, auf denen der MV mit einer Geschwindigkeit > 30 km/h fahren darf (siehe Abbildung *50*).

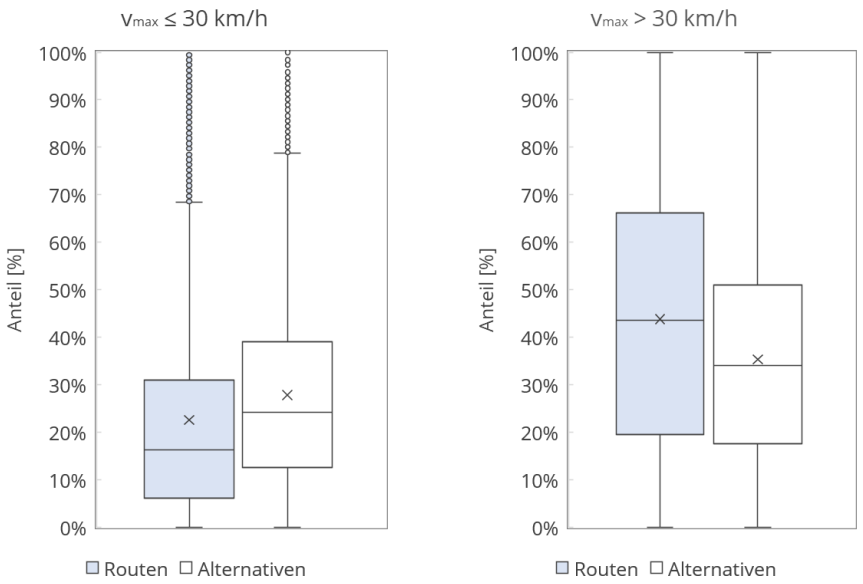


Abbildung 50: Verteilung der Anteile der max. zulässigen Geschwindigkeit ($v_{max}$) des MV entlang der Routen und Alternativen

Auf den gewählten Routen waren die Radfahrenden im Mittel zu 22,5 % (Mittelwert) bzw. 16,2 % (Median) auf Strecken unterwegs, auf denen für den Kfz-Verkehr eine Maximalgeschwindigkeit von 30 km/h zulässig ist. Dieser Anteil ist entlang der nicht gewählten Alternativen mit rund 27,8 % (Mittelwert) bzw. 24,2 % (Median) deutlich höher. Die durchschnittlichen Anteile von Streckenabschnitten mit einer maximal zulässigen Geschwindigkeit von mehr als 30 km/h beträgt entlang der genutzten Routen 43,8 % (Mittelwert) bzw. 43,5 % (Median). Die Werte fallen bei den nicht gewählten Alternativen mit 35,3 % (Mittelwert) bzw. 34,0 % (Median) geringer aus. Abbildung *50* verdeutlicht die Verteilung der Merkmalsausprägungen für die Routen und Alternativen.

Die Betrachtung der einzelnen Werte ließe auch für diese Variable vermuten, dass die Radfahrenden eher Routen bevorzugen, entlang derer der MV höhere Geschwindigkeiten realisieren darf. Die Verteilung der Merkmalsausprägungen ist jedoch auch bei den betrachteten Variablen aufgrund relativ hoher Anteile fehlender Informationen (siehe Abbildung *51*) nur schwer zu interpretieren.

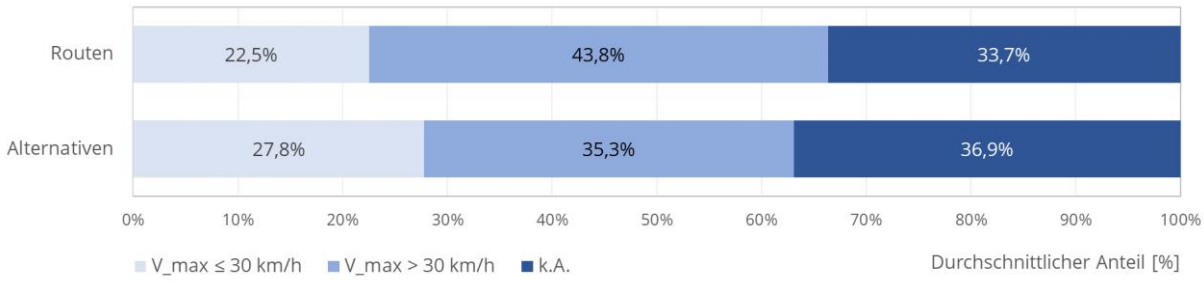


Abbildung 51: Durchschnittliche Streckenanteile der max. zulässigen Geschwindigkeit ($v_{max}$) des MV entlang der Routen und Alternativen

Einerseits könnten die leicht höheren Anteile in Zusammenhang mit der Datenverfügbarkeit stehen. Andererseits zeigten sich bereits in der Korrelationsanalyse mittelstarke Zusammenhänge mit anderen Variablen (z.B. $r$ = -0,4703 mit dem Vorhandensein von Radverkehrsinfrastruktur), sodass die Ausprägung der vorliegenden Variablen durch andere Faktoren beeinflusst sein könnte.

### *j) Ruhender Verkehr*

Die Betrachtung des ruhenden Verkehrs und seiner unterschiedlichen Anordnungen offenbart kaum Unterschiede zwischen Routen und Alternativen (siehe Abbildung *52*). Im Mittel sind die Anteile von längs angeordnetem ruhendem Verkehr entlang der Routen und Alternativen mit rund 21 % gleich groß. Lediglich beim Median sind leichte Unterschiede zu beobachten, die auf eine Vermeidung von längs angeordnetem ruhendem Verkehr schließen lassen. So beträgt der Anteil bei den gewählten Routen rund 16,5 %, während er bei den nicht gewählten Alternativen etwa 18,7 % ausmacht. Der Anteile sonstiger Anordnungsarten zeigen mit jeweils 1,8 % (Mittelwert) und 0,0 % (Median) faktisch keine Unterschiede zwischen Routen und Alternativen auf.

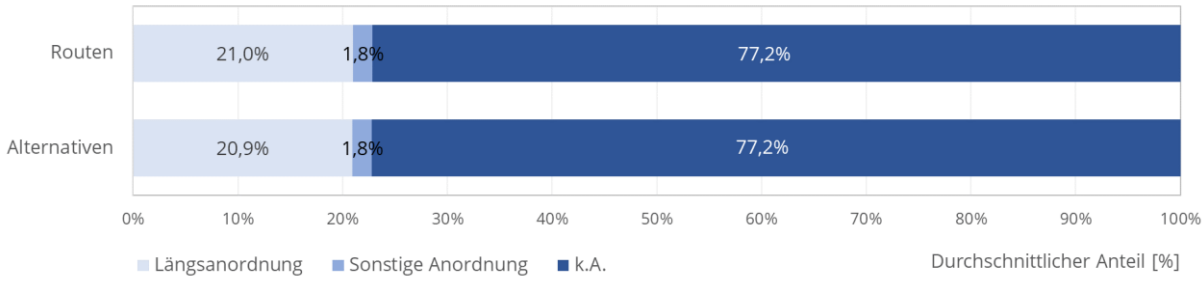


Abbildung 52: Durchschnittliche Anteile der Anordnungsformen des ruhenden Verkehrs entlang der Routen und Alternativen

Die geringen Unterschiede werden auch bei der detaillierten Betrachtung der Verteilung deutlich (siehe Abbildung *53*). Sie fallen, abgesehen von der Streuung und dem Median, sehr gering aus.

Aufgrund der Tatsache, dass sich im Rahmen der deskriptiven Auswertung kaum Unterschiede zwischen gewählten Routen und deren Alternativen ergeben, fällt es schwer, diesbezüglich erste Erkenntnisse festzuhalten. Der im Vergleich zu den Alternativen kleinere Anteil längs angeordneten ruhenden Verkehrs (Median) entlang der Routen könnte auf eine Vermeidung hinweisen.

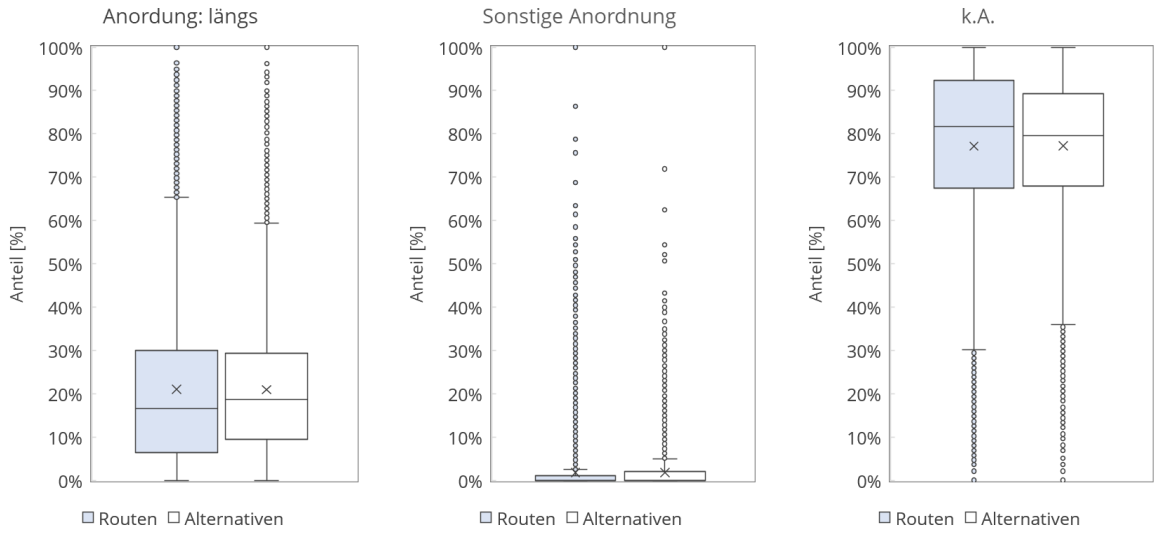


Abbildung 53: Verteilung der Anordnungsformen des ruhenden Verkehrs entlang der Routen und Alternativen

### *l) Sicherheit*

Die deskriptive Auswertung der Variablen „Unfallhäufigkeit“ und „kritische Situationen“ zeigt leichte Unterschiede zwischen Routen und Alternativen auf. Die von den Radfahrenden gewählten Routen passieren im Durchschnitt rund 29,5 (Mittelwert) bzw. 25,5 (Median) Unfallpunkte je gefahrenem Kilometer entlang ihrer Route. Dieser Wert fällt mit ca. 24,1 (Mittelwert) bzw. 21,1 (Median) Unfällen je Streckenkilometer entlang der nicht gewählten Alternativen rund 20 % geringer aus.

Es existieren sowohl Routen als auch Alternativen, entlang derer keine Unfälle stattgefunden haben, wodurch die Unfallhäufigkeit ein Minimum von Null erreicht. Als Maximalwert wurden jeweils 246 Unfälle/km erreicht. Dieser sehr hohe Wert lässt sich vermutlich mit kurzen Fahrtweiten entlang von Strecken oder Knotenpunkten mit hohem Unfallaufkommen erklären.

Ein ähnliches Bild ergibt sich bei der Betrachtung von Orten mit kritischen Situationen. Die von den Radfahrenden gewählten Routen beinhalteten insgesamt mehr Punkte, an denen kritische Situationen berichtet wurden, als die Routenalternativen. So lag die durchschnittliche Anzahl von derartigen Punkten mit 2,7 (Mittelwert) bzw. 2,0 (Median) etwa 30 % über dem Wert der Alternativen, die im Durchschnitt rund 1,9 (Mittelwert) bzw. 1,4 (Median) Punkten kritischer Situationen aufwiesen (siehe Tabelle *13*).

Die Betrachtung der Werteverteilung (siehe Abbildung *54*) unterstreicht zunächst den durch die Kennwerte gewonnenen Eindruck. Es lassen sich jedoch lediglich leichte Tendenzen bzgl. der Variablenausprägung erkennen.

| | Unfallhäufigkeit | | Punkte kritischer Situationen | |
|---|---|---|---|---|
| | **Routen** | **Alternativen** | **Routen** | **Alternativen** |
| Minimum | - | - | - | - |
| Mittelwert | 29,47 n/km | 24,12 n/km | 2,72 n/km | 1,94 n/km |
| Median | 25,50 n/km | 21,14 n/km | 1,99 n/km | 1,42 n/km |
| Maximum | 245,86 n/km | 245,86 n/km | 34,03 n/km | 25,75 n/km |
| Streuung | 245,86 n/km | 245,86 n/km | 34,03 n/km | 25,75 n/km |
| Standardabw. | 21,76 n/km | 18,14 n/km | 2,89 n/km | 2,16 n/km |

Tabelle 13: Kennwerte zur Unfallhäufigkeit und Punkte kritischer Situationen entlang der Routen und Alternativen

Dass die gewählten Routen durchschnittlich mehr Unfallpunkte und Orte mit berichteten kritischen Situationen passieren, muss nicht zwangsläufig auf einen positiven Einfluss der vorliegenden Variable zurückzuführen sein. Die Korrelationsanalyse in Kapitel 4.3.1 hat bereits aufgezeigt, dass bspw. die Unfallhäufigkeit mittelstark mit anderen Variablen (z.B. Vorhandensein von Radverkehrsinfrastruktur oder LSA-geregelten Knotenpunkten) korreliert. Daher ist es durchaus denkbar, dass andere Variablen die Präferenzen der Radfahrenden beeinflussen und bspw. Strecken mit hoher Unfallhäufigkeit in Kauf genommen werden, weil andere Faktoren diesen „Nachteil“ überkompensieren.

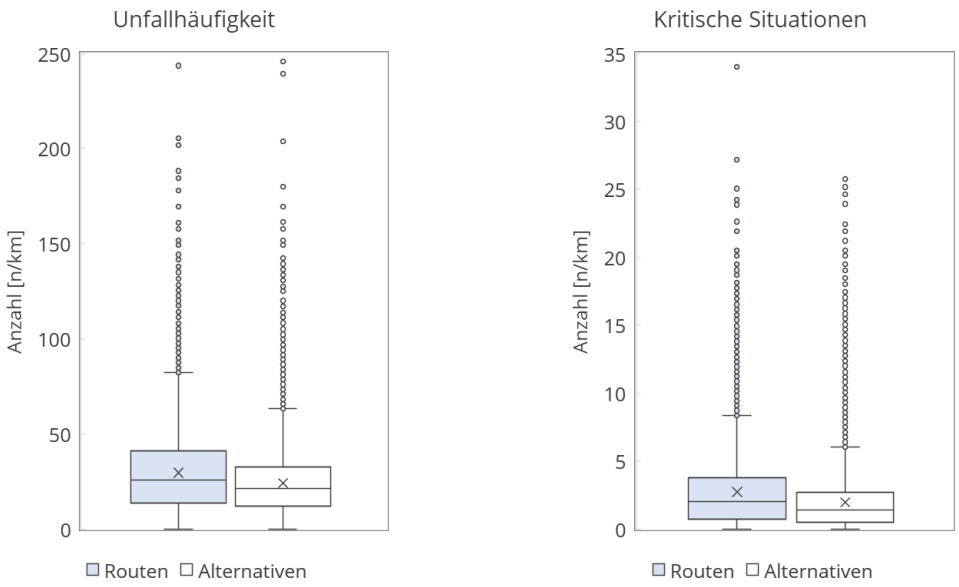


Abbildung 54: Verteilung der Unfallhäufigkeit und Häufigkeit von Punkten kritischer Situationen entlang der Routen und Alternativen

Die Ergebnisse der deskriptiven Auswertung ergeben für die vorliegende Variable ein eher fragmentiertes Bild, zeigen jedoch eine leichte Tendenz zur Nutzung von Routen mit höherer Unfallhäufigkeit und mehr Punkten kritischer Situationen auf.

### *m) Knotenpunkte und deren Regelung*

Die Betrachtung der auf den Routen durchfahrenen Knotenpunkte und deren Art der Regelung zeigt im Vergleich zu den Alternativen geringe Unterschiede auf. Entlang der gewählten Routen passierten die Radfahrenden im Durchschnitt rund 2,8 (Mittelwert) bzw. 2,5 (Median) Knotenpunkte je Streckenkilometer, die „rechts-vor-links" geregelt sind. Mit ca. 2,9 (Mittelwert) bzw. 2,7 (Median) Knotenpunkten je Streckenkilometer fällt der Wert für diese Art der Regelung entlang der Alternativen unwesentlich höher aus. Es existieren sowohl Routen als auch Alternativen, entlang derer keine rechts-vor-links geregelten Knotenpunkte passiert wurden (Min = 0 n/km). Als Maximalwert werden jeweils 15,2 Knotenpunkte je Streckenkilometer erreicht – ein Wert, der sehr hoch erscheint und vermutlich bei sehr kurzen Fahrtweiten entsteht.

| | **Regelung „rechts-vor-links"** | | **Regelung „Lichtsignalanlage"** | |
|---|---|---|---|---|
| | **Routen** | **Alternativen** | **Routen** | **Alternativen** |
| Minimum | - | - | - | - |
| Mittelwert | 2,80 n/km | 2,85 n/km | 1,01 n/km | 0,79 n/km |
| Median | 2,52 n/km | 2,73 n/km | 0,94 n/km | 0,72 n/km |
| Maximum | 15,23 n/km | 15,23 n/km | 8,13 n/km | 8,13 n/km |
| Streuung | 15,23 n/km | 15,23 n/km | 8,13 n/km | 8,13 n/km |
| Standardabw. | 1,70 n/km | 1,52 n/km | 0,82 n/km | 0,65 n/km |

Tabelle 14: Kennwerte zur Regelung an Knotenunkten entlang der Routen und Alternativen

Bei der Betrachtung von Kontenpunkten, die durch eine LSA geregelt sind, ergibt sich ein umgekehrtes Muster. Die von den Radfahrenden gewählten Routen beinhalteten im Durchschnitt mit 1,0 (Mittelwert) bzw. 0,9 (Median) LSA-Knotenpunkten je Streckenkilometer mehr Knotenpunkte dieses Typs, als die nicht gewählten Alternativen. Entlang der Alternativen wurden im Durchschnitt nur rund 0,8 (Mittelwert) bzw. 0,7 (Median) LSA geregelte Knotenpunkte je Streckenkilometer durchfahren (siehe Tabelle *14*).

Diese moderaten Unterschiede spiegeln sich auch in der Verteilung der Merkmalsausprägung aller Routen und Alternativen wieder (siehe Abbildung *55*). Es sind jedoch lediglich leichte Tendenzen zu erkennen, sodass sich an dieser Stelle noch keine eindeutigen Aussagen tätigen lassen. Die Ergebnisse der deskriptiven Auswertung deuten zunächst auf eine leichte Tendenz der Radfahrenden hin, Knotenpunkte LSA-Regelung gegenüber „rechts-vor-links" geregelten Knotenpunkten zu bevorzugen.

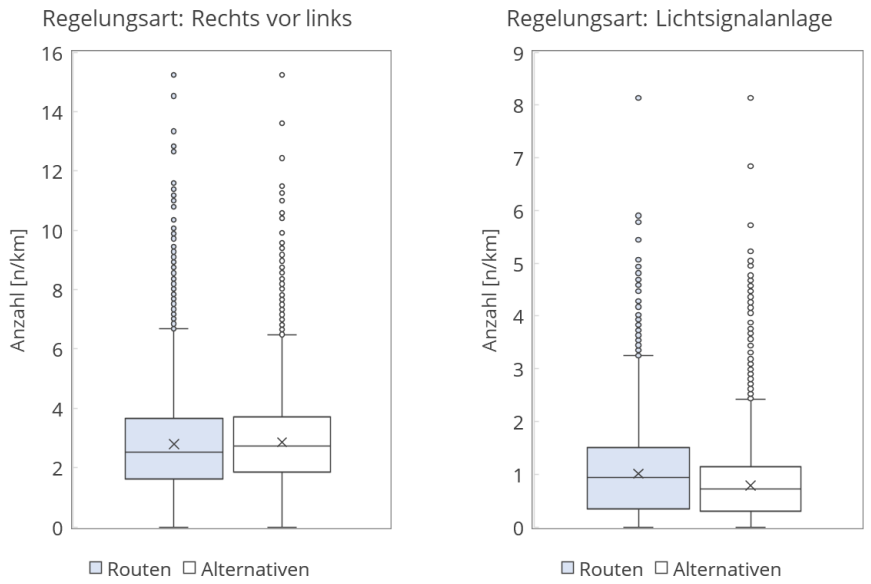


Abbildung 55: Verteilung der Regelungsarten an Knotenpunkten entlang der Routen und Alternativen

### *n) Flächennutzung*

Die Betrachtung der Flächennutzung lässt nur relativ geringe Unterschiede zwischen den gewählten Routen und ihren Alternativen erkennen. Es kann zunächst festgehalten werden, dass insgesamt ein Großteil der Routen und Alternativen entlang von Wohn- und Grünflächen verläuft (siehe Abbildung *56*). Im Mittel machen diese beiden Nutzungsarten mehr als die Hälfte der Flächennutzung entlang der Routen (51,7 %) und Alternativen (51,1 %) aus. Die beiden Flächennutzungen sind demnach die dominierenden Nutzungsarten entlang der Routen/Alternativen in der Stadt (Vgl. ca. 48,3 % bzw. 48,9 % für sonstige Nutzung, die sich aus insgesamt vier weiteren Flächennutzungsarten zusammensetzt).

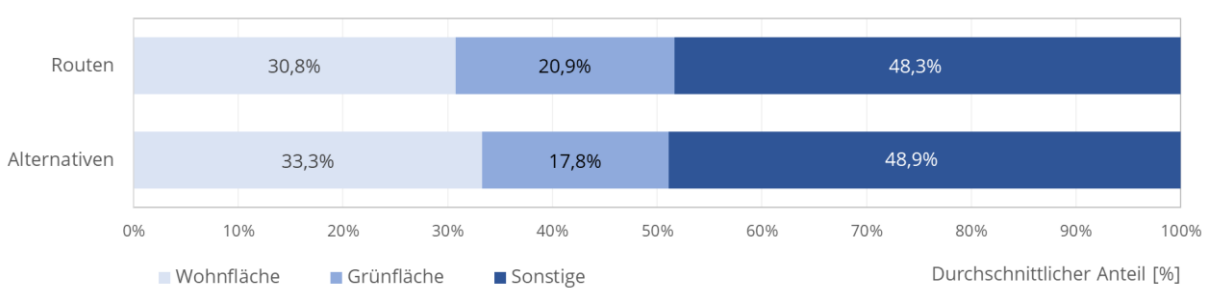


Abbildung 56: Durchschnittliche Anteile der Flächennutzungstypen entlang der Routen und Alternativen

Entlang der gewählten Routen liegt der durchschnittliche Anteil der Flächennutzung „Wohnen“ bei rund 30,8 % (Mittelwert) bzw. 26,8 % (Median). Mit einem durchschnittlichen Anteil von 33,3 % (Mittelwert) bzw. 31,2 % (Median) führen die Alternativen zu etwas größeren Anteilen durch Wohngebiete. Sowohl bei den gewählten Routen als auch bei den

Alternativen existieren jedoch Routen, deren Strecken nahezu vollständig (Maximum jeweils ca. 99 %) oder überhaupt nicht (Minimum jeweils 0 %) durch Wohngebiete verlaufen. Die Unterschiede fallen insgesamt jedoch relativ gering aus.

Die Betrachtung der Grünflächenanteile offenbart eine inverse Verteilung. Die Streckenanteile mit Grünflächen waren entlang der gewählten Routen mit 20,9 % (Mittelwert) bzw. 13,4 % (Median) im Durchschnitt deutlich höher als entlang der Alternativen, bei denen durchschnittlich nur 17,8 % (Mittelwert) bzw. 12,4 % (Median) der Route entlang von Grünflächen verliefen. Minimale und Maximale Anteile sind für Routen und Alternativen identisch (Min = 0 %; Max = 100 %). Die Betrachtung der Verteilung lässt neben den insgesamt eher geringen Unterschieden der Kennwerte (Min, Max, Mittel, Median) jedoch auch eine breitere Verteilung der Merkmalsausprägung entlang der Routen erkennen (siehe Abbildung *57*).

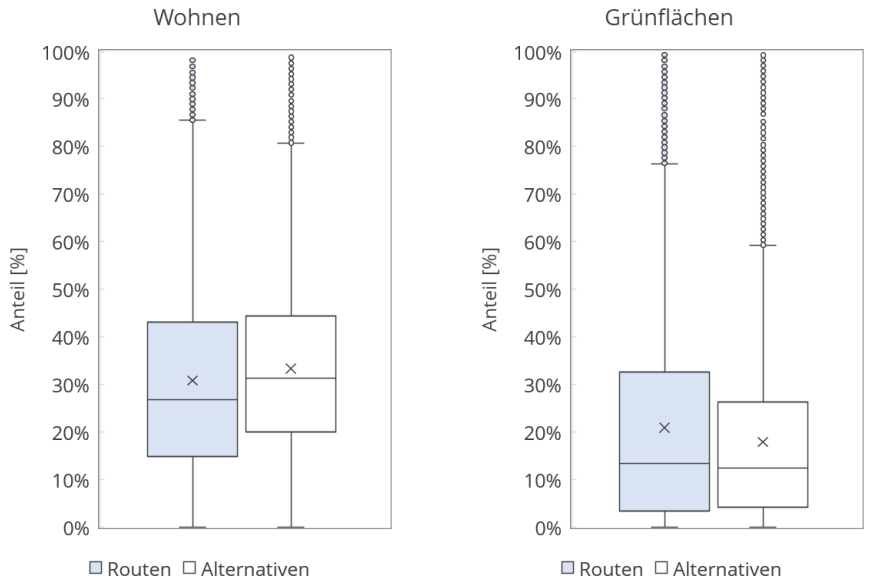


Abbildung 57: Verteilung der Wohn- und Grünflächenanteile entlang der Routen und Alternativen

Es lässt sich festhalten, dass die gewählten Routen im Mittel länger an Grünflächen vorbeiführten und etwas weniger häufig durch Wohngebiete verliefen. Dies könnte auf eine Präferenz der Radfahrenden hinweisen eher Routen durch Parks, Wälder usw. zu wählen und Wohngebiete zu meiden.

### Zusammenfassung

Die deskriptive Auswertung der Merkmale kann wie folgt zusammengefasst werden: Die Radfahrenden wählten eher kürzere Routen mit geringeren Längsneigungen. Sie nutzten auf ihren Wegen vor allem Routen, auf deren Strecken möglichst Radverkehrsinfrastruktur vorhanden war. Darüber hinaus wurden die Wege auf Routen mit möglichst breiten Radwegen zurückgelegt, auf denen auch andere Radfahrende unterwegs waren.

Die gewählten Routen verliefen häufiger entlang von Straßen mit höheren zulässigen Geschwindigkeiten des motorisierten Verkehrs. Eine klare Tendenz zur Meidung oder Bevorzugung von Streckenabschnitten mit einem höheren bzw. niedrigeren $DTV_{Kfz}$ oder mehr bzw. weniger Fahrstreifen ließ sich in der deskriptiven Auswertung nicht erkennen.

Die Radfahrenden waren vornehmlich auf Routen mit höheren Anteilen glatter Oberfläche (Asphalt) unterwegs. Darüber hinaus wiesen die gewählten Routen hohe Grünflächenanteile auf. Es wurden zudem moderat weniger „rechts-vor-links“ und mehr LSA geregelte Knotenpunkte entlang der gewählten Routen beobachtet.

Entlang der gewählten Routen wurden durchschnittlich mehr Unfallpunkte (objektive Sicherheit) sowie mehr Punkte wahrgenommener Unsicherheit (subjektive Sicherheit) passiert, als auf den nicht gewählten Alternativen. Zum ruhenden Verkehr entlang der Routen konnten auf Basis der Daten keine eindeutigen Tendenzen aufgezeichnet werden, sodass sich diesbezüglich ein fragmentiertes Bild ergibt.

## 5.2 Multiple logistische Regressionsanalyse

Um die kausalen Zusammenhänge zwischen den Variablen und der Routenwahl aufzudecken und die Einflussfaktoren der Routenwahl benennen und deren Wirkung abschätzen zu können, werden in den folgenden Abschnitten die Ergebnisse der multivariaten Analyse (multiple logistische Regression) vorgestellt. Damit die Validität der Modellergebnisse insgesamt eingeschätzt werden kann, werden in dem anschließenden Kapitel (Kap. 5.2.2) die Ergebnisse zur Bestimmung der Modell-Güte präsentiert.

Es wird an dieser Stelle darauf hingewiesen, dass in diesem Kapitel lediglich die Ergebnisse vorgestellt werden. Die Kontextualisierung und Interpretation der Resultate erfolgt in Kapitel 6.1.

### 5.2.1 Einflussfaktoren der Routenwahl

Die Ergebnisse der multivariaten Analyse zeigen die kausalen Zusammenhänge zwischen der Routenwahl und ihren Einflussfaktoren auf. In den folgenden Abschnitten werden Richtung (positiv, negativ) und Stärke aller in die Analyse einbezogenen Einflussfaktoren präsentiert. Um die Wirkung und Relevanz der Faktoren auf die Routenwahl besser einschätzen zu können, wird auf die in Kapitel 4.3.2 beschriebene Odds Ratio sowie die Signifikanz der jeweiligen Einflussfaktoren eingegangen. Die zentralen Ergebnisse der Analyse sind in Tabelle *15* zusammengefasst. Auf die Tabelle und die einzelnen Werte der unterschiedlichen Einflussfaktoren wird in den anschließenden Abschnitten dezidiert eingegangen.

| Unabhängige Variable | Korr. koeff. | Stand. abw. | Sign. | Odds Ratio | 95% Konfidenzint. (Odds Ratio) untere | obere |
|---|---|---|---|---|---|---|
| Distanz | -0,301 | 0,020 | 0,000 | 0,740 | 0,712 | 0,769 |
| Maximale Längsneigung | -0,058 | 0,004 | 0,000 | 0,943 | 0,936 | 0,951 |
| Längsneigung < 2 % | 1,373 | 0,297 | 0,000 | 3,947 | 2,206 | 7,062 |
| Längsneigung > 2 % | -1,084 | 0,470 | 0,021 | 0,338 | 0,135 | 0,851 |
| Radverkehrsinfrastruktur | 4,205 | 0,192 | 0,000 | 67,007 | 45,959 | 97,695 |
| Breite der RVF < 1,5 m | -2,067 | 0,292 | 0,000 | 0,127 | 0,071 | 0,224 |
| Asphaltoberfläche | 2,210 | 0,184 | 0,000 | 9,114 | 6,354 | 13,072 |
| Kopfsteinpflasteroberfläche | 0,192 | 0,360 | 0,595 | 1,211 | 0,598 | 2,453 |
| $DTV_{Rad}$ > 500 | 4,158 | 0,131 | 0,000 | 63,914 | 49,450 | 82,608 |
| $DTV_{Kfz}$ (Mittelwert) | 0,000 | 0,000 | 0,379 | 1,000 | 1,000 | 1,000 |
| 1 Fahrstreifen MV | 1,209 | 0,183 | 0,000 | 3,351 | 2,339 | 4,802 |
| $v_zul_{Kfz}$ < 30 km/h | 1,140 | 0,135 | 0,000 | 3,126 | 2,402 | 4,069 |
| Ruhender Verkehr (Längsaufst.) | -0,152 | 0,183 | 0,405 | 0,859 | 0,600 | 1,229 |
| Unfallhäufigkeit | -0,010 | 0,002 | 0,000 | 0,990 | 0,987 | 0,994 |
| Häufigkeit krit. Situationen | 0,066 | 0,013 | 0,000 | 1,068 | 1,042 | 1,095 |
| Häufigkeit von KP mit Regelung „rvl" | 0,016 | 0,020 | 0,432 | 1,016 | 0,977 | 1,056 |
| Häufigkeit von KP mit LSA | 0,408 | 0,044 | 0,000 | 1,504 | 1,380 | 1,638 |
| Grünflächenanteil | 2,218 | 0,182 | 0,000 | 9,188 | 6,434 | 13,120 |
| Wohngebietsflächenanteil | 0,901 | 0,163 | 0,000 | 2,463 | 1,790 | 3,388 |

Tabelle 15: Ergebnisse der logistischen Regressionsanalyse

### *a) Distanz*

Die Distanz einer Route übt im analysierten Datensatz einen wesentlichen Einfluss auf die Auswahlwahrscheinlichkeit einer Route aus. Der Korrelationskoeffizient für die Variable ist -0,301. Die Distanz beeinflusst die Routenwahl demzufolge negativ. Mit zunehmender Distanz sinkt der Nutzen einer Route (durch Multiplikation der Variable mit dem negativen Korrelationskoeffizienten). Folglich reduziert sich auch die Wahrscheinlichkeit der Wahl einer Route auf einer Verkehrsrelation, wenn die Route länger wird. Die Signifikanz von 0,000 zeigt an, dass der Einfluss der Variable hochsignifikant ist.

Die Odds Ratio (0,740) bestätigt einen signifikanten Zusammenhang, weil sie keinen Wert von OR = 1 annimmt. Daher kann von einem signifikanten Einfluss dieser unabhängigen Variable auf die Routenwahl ausgegangen werden. Die Odds Ratio bestätigt zudem den gefundenen negativen Zusammenhang, weil OR < 1 ist.

Der negative Einfluss einer steigenden Distanz auf die Wahlwahrscheinlichkeit einer Route wird an folgendem Beispiel deutlich: Auf einer Verkehrsrelation existieren zwei Routen, die exakt die gleichen Eigenschaften besitzen. Die Eigenschaften entsprechen in dem vorliegenden Beispiel jenen einer durchschnittlichen Route im Datensatz (siehe Kapitel 5.1). Die Wahlwahrscheinlichkeit beider Routen beträgt in diesem Fall jeweils 50 %. Erhöht sich die Distanz auf einer der beiden Routen um 10 % (0,47 km), so verringert sich

die Wahrscheinlichkeit der Wahl dieser (längeren) Route um -3,5 % auf 46,5 %. Die Wahlwahrscheinlichkeit der kürzeren Route fällt entsprechend höher aus (53,5 %) und es ergäbe sich demnach eine Differenz zwischen den Wahrscheinlichkeiten von rund 7 %.

Radfahrende präferieren folglich kürzere Routen. Damit bestätigt sich der Eindruck aus den deskriptiven Analysen, die auf einen Einfluss der Fahrtweite auf die Routenwahl hindeuteten.

#### *b) Längsneigung*

Die Längsneigung entlang einer Route besitzt ebenfalls einen wesentlichen Einfluss auf die Routenwahl, wirkt sich jedoch in unterschiedlichem Maße auf die Auswahlwahrscheinlichkeit einer Route aus. Die maximal vorhandene Längsneigung entlang einer Route übt sich negativ auf die Auswahl einer Route aus. Der Korrelationskoeffizient für die Variable ist -0,058. Dementsprechend sinkt der Nutzen einer Route mit zunehmender maximaler Längsneigung. Aus diesem Grund reduziert sich auch die Wahlwahrscheinlichkeit einer Route auf einer Verkehrsrelation, wenn die maximale Längsneigung einer Route steigt. Die Signifikanz von 0,000 zeigt an, dass dieser Einfluss hochsignifikant ist.

Die Odds Ratio von OR = 0,943 bestätigt einen signifikanten Zusammenhang (OR ≠ 1), wodurch von einem signifikanten Einfluss der unabhängigen Variable auf die Routenwahl ausgegangen werden kann. Sie bestätigt zudem den negativen Zusammenhang (OR < 1).

Der negative Einfluss einer größeren maximalen Längsneigung auf die Wahlwahrscheinlichkeit einer Route kann ebenfalls an dem bereits angeführten Beispiel verdeutlicht werden: Erhöht sich die max. Längsneigung auf einer der beiden Routen um 1 %, so verringert sich die Wahrscheinlichkeit der Auswahl dieser Route um rund -1,4 % auf 48,6 %. Die Wahlwahrscheinlichkeit der anderen Route fällt entsprechend höher aus (51,4 %) und es ergibt sich eine Differenz der Wahlwahrscheinlichkeiten von rund 2,8 %. Der Korrelationskoeffizient und die OR sowie das angeführte Beispiel zeigen jedoch, dass der Einfluss der maximalen Längsneigung bei der Routenwahl durch die Radfahrenden vergleichsweise schwach ausfällt. Auf Basis der deskriptiven Analysen wurde ein deutlich stärkerer Einfluss auf die Routenwahl vermutet.

Der Einfluss von Streckenabschnitten mit einer Längsneigung < 2 % bzw. > 2 % ist hingegen deutlich stärker ausgeprägt. Höhere Routenanteile mit einer Längsneigung < 2 % üben sich positiv auf die Wahl einer Route aus. Der Korrelationskoeffizient für die Variable ist 1,373. Damit steigt der Nutzen und auch die Wahrscheinlichkeit einer Route, wenn sich der Anteil der Route mit einer Längsneigungen < 2 % erhöht. Die Signifikanz von 0,000 zeigt zudem an, dass der Einfluss der Variable hochsignifikant ist. Die Odds Ratio von

OR = 3,947 bestätigt den signifikant positiven Zusammenhang zwischen der Variable und der Routenwahl.

Zunehmende Anteile einer Route mit einer Längsneigung > 2 % üben sich hingegen negativ auf die Wahl einer Route aus. Der Korrelationskoeffizient für die Variable beträgt -1,0884. Der Nutzen und die Wahrscheinlichkeit einer Route sinkt dementsprechend, wenn der Anteil einer Route mit Strecken von einer Längsneigungen > 2 % ansteigt. Die Signifikanz von 0,021 offenbart, dass der Einfluss der Variable (noch) signifikant ist (Schwellwert der Signifikanz = 0,05). Die Odds Ratio von OR = 0,338 bestätigt einen signifikant negativen Zusammenhang zwischen der Variable und der Routenwahl.

Der Einfluss der beiden Variablen auf die Wahlwahrscheinlichkeit einer Route lässt sich gut an dem obigen Beispiel verdeutlichen: Erhöht sich der Anteil von Streckenabschnitten mit einer Längsneigung < 2 % von durchschnittlich 39,3 % auf 49,3 %, so erhöht sich die Wahrscheinlichkeit der Wahl dieser Route um rund 3,6 % auf 53,4 %. Es ergibt sich eine Differenz der Wahlwahrscheinlichkeit von 6,8 % zwischen beiden Routen. Eine Verdopplung der Streckenanteile auf 78,6 % führt zu einer Erhöhung der Wahlwahrscheinlichkeit auf 63,2 %. Die Wahlwahrscheinlichkeit der anderen Route fällt entsprechend gering aus (36,8 %). Demgegenüber führt die Erhöhung des Routenanteils mit einer Längsneigung > 2 % zu einer Verringerung der Auswahlwahrscheinlichkeit. Eine Erhöhung von bspw. 10 % (auf 17,5 %) verringert die Wahrscheinlichkeit der Wahl dieser Route durch die Radfahrende um -2,7 % auf 47,3 % (Differenz von 5,4 % zwischen beiden Routen).

Der Korrelationskoeffizient, die OR und das obige Beispiel zeigen, dass der Einfluss der Streckenanteile einer Route, entlang derer die Längsneigung < 2 % bzw. > 2 % ist, die Routenwahl der Radfahrenden vergleichsweise stark beeinflussen. Die Ergebnisse der deskriptiven Statistik ließen bereits einen derartigen Zusammenhang vermuten.

#### *c) Radverkehrsführungsform*

Das Vorhandensein von Radverkehrsinfrastruktur übt im analysierten Datensatz einen wesentlichen Einfluss auf die Auswahlwahrscheinlichkeit einer Route aus. Der Korrelationskoeffizient für die Variable ist 4,205. Die Variable beeinflusst die Routenwahl demzufolge positiv. Mit einem zunehmenden Anteil von Streckenabschnitten, die über Radverkehrsinfrastruktur verfügen, steigt deren Nutzen für die Radfahrenden und die Auswahlwahrscheinlichkeit einer Route steigt entsprechend stark an. Die Signifikanz der Variable (Sign. = 0,000) zeigt auf, dass der Einfluss hochsignifikant ist.

Die Signifikanz wird zudem durch den Wert der Odds Ratio bestätigt (OR > 0). Die OR = 67,007 zeigt darüber hinaus an, dass es sich um einen signifikant positiven Zusammenhang handelt.

Der positive Einfluss vorhandener Radverkehrsinfrastruktur auf die Auswahlwahrscheinlichkeit einer Route wird ebenfalls am Beispiel deutlich: Erhöht sich auf einer der beiden Routen der Anteil von Streckenabschnitten, auf denen Radverkehrsinfrastruktur vorhanden ist, um +10 % (also vom durchschnittlichen Anteil von 33,3 % auf 43,3 %), erhöht sich die Auswahlwahrscheinlichkeit dieser Route um 10,4 % auf 60,4 %. Die Wahlwahrscheinlichkeit der alternativen Route fällt mit 39,6 % entsprechend geringer aus. Es ergibt sich eine Differenz von rund 20,8 %. Eine Verdopplung des Streckenanteils mit Radverkehrsinfrastruktur auf 66,6 % lässt die Auswahlwahrscheinlichkeit dieser Route sogar auf 80,2 % ansteigen und hat eine noch höhere Differenz der Wahlwahrscheinlichkeiten zur Folge (60,4 %).

Die Radfahrenden der Stichprobe zeigen also eine starke Präferenz zur Wahl ihrer Route in Abhängigkeit von vorhandener Radverkehrsinfrastruktur. Die deutlich ausgeprägte Präferenz wurde bereits im Rahmen der deskriptiven Auswertung vermutet.

#### *d) Breite der Radverkehrsführung*

Die Analyseergebnisse zeigen, dass die Breite der Radverkehrsführung ebenfalls die Routenwahl der Radfahrenden beeinflusst. Die Variable „Breite der Radverkehrsführung < 1,5 m“ weist einen Korrelationskoeffizienten von -2,0677 auf. Sie beeinflusst die Routenwahl demzufolge negativ. Steigt der Anteil von Streckenabschnitten einer Route, entlang derer die Breite der Radverkehrsführung geringer als 1,5 m ist, so sinken deren Nutzen für die Radfahrenden und die Auswahlwahrscheinlichkeit dieser Route sinkt stark. Der Einfluss der Variable ist hochsignifikant (Sign. = 0,000).

Die Odds Ratio (0,127) der Variable bestätigt den signifikanten Zusammenhang. Es kann daher von einem signifikanten negativen (OR < 1) Einfluss der unabhängigen Variable auf die Routenwahl ausgegangen werden.

Der negative Einfluss der Breite der Radverkehrsführung auf die Auswahlwahrscheinlichkeit einer Route wird auch im erwähnten Beispiel deutlich: Eine Erhöhung des Streckenanteils mit einer Breit < 1,5 m von +10 % (von durchschnittlich 76,2 % auf 86,2 %) führt zu einer absinkenden Auswahlwahrscheinlichkeit (-5,1 %) dieser Route auf 44,9 %. Die Wahlwahrscheinlichkeit der alternativen Route steigt dementsprechend auf 55,1 % und es ergibt sich eine Differenz zwischen den Wahrscheinlichkeiten von rund 10,2 %. Eine Verringerung des Streckenanteils auf 50,0 % führt hingegen zu einem starken Anstieg der Wahrscheinlichkeit (+13,2 %), sodass sich eine Differenz von 26,4 % zwischen den resultierenden Wahlwahrscheinlichkeiten der beiden Routen (63,2 % vs. 36,8 %) ergibt.

Es zeigt sich insgesamt, dass die Routenwahl der Radfahrenden stark durch die Breite der vorhandenen Radverkehrsinfrastruktur beeinflusst wird. Die Ergebnisse der Regressionsanalyse stützen damit die Vermutungen der deskriptiven Auswertung.

***e) Oberflächenbeschaffenheit***

Die Oberflächenbeschaffenheit einer Route übten, in Abhängigkeit ihrer Ausprägung, einen wesentlichen Einfluss auf die Routenwahl aus. Höhere Anteile des Oberflächentyps „Asphalt“ entlang einer Route beeinflussen die Wahl einer Route positiv. Der Korrelationskoeffizient für die Variable beträgt 2,210. Dementsprechend steigt die Wahrscheinlichkeit einer Route, wenn der Anteil der Route mit asphaltgedeckten Streckenabschnitten ansteigt. Die Signifikanz von 0,000 zeigt zudem, dass der Einfluss der Variable hochsignifikant ist. Die Odds Ratio von OR = 9,114 bestätigt diesen signifikant positiven Zusammenhang zwischen der Variable und der Routenwahl.

Der Einfluss der Variable auf die Wahlwahrscheinlichkeit einer Route lässt sich gut an dem obigen Beispiel verdeutlichen: Erhöht sich der Anteil von Streckenabschnitten mit Asphaltdecke von durchschnittlich 53,7 % auf 63,7 %, so erhöht sich die Auswahlwahrscheinlichkeit dieser Route um rund 5,5 % auf 55,5 %. Es ergibt sich eine Differenz der Wahrscheinlichkeit von 11,0 % zwischen beiden Routen. Eine Erhöhung der Streckenanteile auf 80,0 % führt zu einer Erhöhung der Wahlwahrscheinlichkeit auf 64,1 % (die Wahlwahrscheinlichkeit der anderen Route fällt mit 35,9 % entsprechend gering aus). Auch wenn die deskriptive Auswertung der Daten bereits einen derartigen Zusammenhang hatte vermuten lassen, so ist die Stärke des analysierten Zusammenhangs jedoch beachtlich.

Die Betrachtung des Oberflächentyps „Kopfsteinpflaster“ zeigt, dass höhere Anteile von mit Kopfstein gedeckten Oberflächen eine schwach positive Wirkung auf die Routenwahl ausüben (der Korrelationskoeffizient beträgt 0,192). Dementsprechend führt eine Erhöhung des Kopfsteinpflasteranteils entlang einer Route zu einer Erhöhung der Wahlwahrscheinlichkeit. Die Signifikanz von 0,595 macht jedoch deutlich, dass der gefundene Zusammenhang statistisch nicht gesichert ist. Dies wird auch bei der Betrachtung des Konfidenzintervalls der Odds Ratio deutlich, welches zwischen 0,598 und 2,453 liegt. Schließt das Konfidenzintervall den Wert 1 ein, deutet das auf einen nicht signifikanten Zusammenhang hin. Aufgrund der hohen Streuung und vielen Ausreißer der Variable (siehe deskriptive Statistik) wurde ein derartiges Ergebnis erwartet.

### *f) Radverkehrsstärken*

Das Vorhandensein weiterer Radfahrender entlang einer Route übt im analysierten Datensatz einen starken und signifikanten Einfluss auf die Routenwahl aus. Der Korrelationskoeffizient der Variable „$DTV_{Rad}$ > 500“ ist mit 4,158 im Vergleich zu den Koeffizienten anderer Variablen sehr hoch. Die Variable beeinflusst die Routenwahl demzufolge stark positiv. Ein steigender Anteil von Streckenabschnitten entlang der Route, auf denen der $DTV_{Rad}$ > 500 ist, führt zu einer ansteigenden Auswahlwahrscheinlichkeit einer Route. Die Variable ist mit einer Signifikanz von 0,000 zudem hochsignifikant.

Die Signifikanz wird zudem durch den sehr hohen Wert der Odds Ratio (OR = 63,914) bestätigt, der einen signifikanten und stark positiven Zusammenhang anzeigt.

Der positive Einfluss einer hohen durchschnittlich täglichen Verkehrsstärke entlang der Routen wird ebenfalls im nachfolgenden Beispiel deutlich: Erhöht sich der Anteil von Streckenabschnitten mit einem $DTV_{Rad}$ > 500 auf einer der beiden Routen von durchschnittlich 52,7 % um +10 % auf 62,7 %, so erhöht sich die Wahrscheinlichkeit der Auswahl dieser Route um 10,2 % auf 60,2 %. Die Auswahlwahrscheinlichkeit der alternativen Route fällt entsprechend geringer aus (39,8 %) und es ergibt sich eine relativ hohe Differenz der Wahrscheinlichkeit zwischen beiden Routen von rund 20,5 %. Eine Erhöhung des Streckenanteils auf 80 % ließe die Auswahlwahrscheinlichkeit der Route sogar auf 75,7 % ansteigen.

Das Vorhandensein anderer Radfahrender entlang einer Route scheint die Routenwahl der Radfahrenden in der Stichprobe stark zu beeinflussen. Ein derartiges Ergebnis wurde auf Basis der deskriptiven Auswertung erwartet.

### *g) Kraftfahrzeugverkehrsstärke*

In der multivariaten Analyse konnte insgesamt kein Einfluss der durchschnittlichen Kraftfahrzeugverkehrsstärke entlang einer Route auf die Routenwahl nachgewiesen werden.

Die Variable „$DTV_{Kfz}$“ weist einen Korrelationskoeffizienten von 0,000 auf und beeinflusst die Routenwahl demzufolge nicht. Die Variable spielt demnach keine Rolle bei der Routenwahl, da eine Erhöhung/Verringerung des durchschnittlichen $DTV_{Kfz}$ entlang der Route zu keiner Änderung von deren Auswahlwahrscheinlichkeit führt. Der (nicht vorhandene) Einfluss der Variable ist zudem statistisch hochsignifikant (Sign. = 0,000).

Der gefundene Zusammenhang wird durch die Odds Ratio (OT = 1,000) bestätigt. Es kann demnach von keinem signifikant positiven/negativen Einfluss der unabhängigen Variable auf die Routenwahl ausgegangen werden.

Dass die Routenwahl der Radfahrenden in der Stichprobe nicht durch den $DTV_{Kfz}$ beeinflusst wird, wurde bereits anhand der Ergebnisse der deskriptiven Analyse vermutet. Es zeigte sich bereits an dieser Stelle, dass die Unterschiede der durchschnittlich täglichen Verkehrsstärke zwischen den Routen und Alternativen marginal sind. Insofern überrascht das Ergebnis mit Blick auf die Daten nicht, obwohl ein Einfluss der durchschnittlich täglichen Verkehrsstärke des Kfz-Verkehrs auf die Routenwahl durchaus denkbar wäre. Inwiefern sich die Ergebnisse mit Resultaten anderer Forschungsarbeiten decken und wie die Ergebnisse der vorliegenden Arbeit zu interpretieren und zu erklären sind, wird in Kapitel 6 erörtert und diskutiert.

***h) Fahrstreifenanzahl***

Zur Untersuchung des Einflussfaktors wurde die Variable „1 Fahrstreifen des MV“ in die Analyse aufgenommen. Der Korrelationskoeffizient von 1,209 weist auf einen positiven Zusammenhang zwischen der Variable und der Routenwahl hin. Steigt der Anteil von Streckenabschnitten einer Route, entlang derer dem Kfz-Verkehr ein Fahrstreifen zur Verfügung steht, so steigt der Nutzen und damit auch die Auswahlwahrscheinlichkeit dieser Route an. Der Einfluss der Variable ist zudem hochsignifikant (Sign. = 0,000). Die Odds Ratio von OR = 3,351 bestätigt den Zusammenhang. Es kann daher von einem signifikant positiven Einfluss der Variable auf die Routenwahl ausgegangen werden.

Der positive Einfluss der Variable auf die Auswahlwahrscheinlichkeit einer Route wird auch im Beispiel der beiden Routen deutlich: Die Erhöhung der Streckenanteile, auf denen dem Kfz-Verkehr nur ein Fahrstreifen zur Verfügung steht, führt zu einer ansteigenden Auswahlwahrscheinlichkeit dieser Route. So führt bspw. eine Erhöhung (+10 %) auf 50,1 % zu einem Anstieg der Wahlwahrscheinlichkeit auf 53,0 %. Die Wahrscheinlichkeit der alternativen Routen sinkt entsprechend und es ergibt sich eine Differenz von rund 6,0 %. Eine Halbierung des Streckenanteils (auf rund 20 %), auf denen dem Kfz-Verkehr nur ein Fahrstreifen zur Verfügung steht, führt hingegen zu einem Absinken der Auswahlwahrscheinlichkeit (-6,0 %) auf 44,0 %.

Es zeigt sich insgesamt, dass die Routenwahl der Radfahrenden in der Stichprobe durch die Anzahl der Fahrstreifen des MV beeinflusst wird. Die Analyseergebnisse offenbaren eine Präferenz der Radfahrenden zur Nutzung von Routen, entlang derer dem Kfz-Verkehr nur ein Fahrstreifen zur Verfügung steht. Das Ergebnis der multivariaten Analyse ist damit eindeutiger, als es die Auswertung der deskriptiven Statistik erscheinen ließ.

### *i) Zulässige Höchstgeschwindigkeit des Kfz-Verkehrs*

Die Analyse belegt, dass die zulässige Höchstgeschwindigkeit des MV einen wesentlichen Einfluss auf die Routenwahl ausübt. Der Korrelationskoeffizient der Variable „$v_zul_{Kfz}$ < 30 km/h“ von 1,140 zeigt auf, dass die Variable die Routenwahl positiv beeinflusst. Ein steigender Anteil von Streckenabschnitten entlang der Route, auf denen die maximal zulässige Geschwindigkeit des Kfz-Verkehrs bis zu 30 km/h beträgt, führt also zu einer höheren Auswahlwahrscheinlichkeit dieser Route. Der Einfluss der Variable ist mit einer Signifikanz von 0,000 zudem hochsignifikant.

Die Signifikanz wird auch durch die Odds Ratio von OR = 3,126 bestätigt. Es kann daher von einem signifikanten positiven Einfluss der unabhängigen Variable auf die Routenwahl ausgegangen werden.

Der positive Einfluss einer niedrigen zulässigen Maximalgeschwindigkeit des Kfz-Verkehrs (bzw. ein hoher Anteil der Geschwindigkeitsbegrenzung entlang der Route) wird ebenfalls im Beispiel deutlich: Eine 10%-ige Erhöhung des durchschnittlichen Anteils (22,5 %) von Streckenabschnitten, auf denen der Kfz-Verkehr nicht schneller als 30 km/h fahren darf, führt zu einer um 5,6 % höheren Auswahlwahrscheinlichkeit dieser Route gegenüber der Alternative (52,8 % vs. 47,2 %). Eine Verdopplung des Streckenanteils auf 45,0 % erhöht die Auswahlwahrscheinlichkeit dieser Route moderat auf 56,4 %. Es ergibt sich eine Differenz der Wahrscheinlichkeiten beider Routen von 12,8 %.

Das Vorhandensein von Streckenabschnitten, auf denen der Kfz-Verkehr nicht schneller als 30 km/h fahren darf, beeinflusst die Routenwahl der Radfahrenden in der Stichprobe also signifikant positiv. Dieses Ergebnis wirkt mit Blick auf die deskriptiven Auswertungen zunächst überraschend. Es wird insgesamt aber als intuitiv erklärbar angesehen (siehe Kapitel 6).

### *j) Ruhender Verkehr*

Der ruhendende Verkehr besitzt keinen wesentlichen Einfluss auf die Routenwahl. Das Vorhandensein von längs angeordnetem bzw. aufgestelltem ruhenden Verkehr entlang einer Route beeinflusst die Routenwahl entsprechend dem Korrelationskoeffizient von -0,152 zwar negativ. Allerdings ist der gefundene Zusammenhang als statistisch nicht gesichert zu betrachten. Dies wird bei der Betrachtung der Signifikanz von 0,405 deutlich.

Gestützt werden die Aussagen auch durch die Odds Ratio und deren Konfidenzintervall. Mit einer OR = 0,859 kann von einem negativen Einfluss der Variable auf die Routenwahl ausgegangen werden. Das Konfidenzintervall von 0,600 bis 1,229 schließt allerdings den Wert eins ein und somit kann nicht von einem signifikanten Einfluss der unabhängigen Variable auf die Routenwahl ausgegangen werden.

***l) Sicherheit***

Sowohl die Unfallhäufigkeit (objektive Sicherheit) als auch die Anzahl kritischer Situationen (subjektive Sicherheit) üben im verwendeten Datensatz lediglich einen schwachen Einfluss auf die Routenwahl der Radfahrenden der Stichprobe aus.

Die Unfallhäufigkeit entlang einer Route wirkt sich leicht negativ auf die Wahl einer Route aus. Der Korrelationskoeffizienten der Variable ist -0,010. Steigt die Unfallhäufigkeit entlang einer Route, so sinken Nutzen und Auswahlwahrscheinlichkeit dieser Route leicht. Dies verdeutlicht auch die Gegenüberstellung der Routen im angesprochenen Beispiel: Erhöht sich die Unfallhäufigkeit entlang einer Route um +10,0 % von durchschnittlich 29,5 Unfällen/km auf 32,4 Unfälle/km, so sinkt die Wahrscheinlichkeit der Auswahl dieser Route von 50,0 % auf 49,3 %. Eine Verdopplung der Unfallhäufigkeit auf 59 Unfälle/km entlang der Route führt zu einer Reduktion der Wahlwahrscheinlichkeit auf 42,7 %. Dies verdeutlicht, dass der Einfluss der Variable auf die Routenwahl vergleichsweise schwach ausfällt. Der analysierte schwache Einfluss der Variable ist dennoch hochsignifikant (Sign. = 0,000). Dies wird auch durch die Odds Ratio von OR = 0,990 bestätigt. Es kann daher von einem signifikant negativen, wenngleich recht schwachen, Einfluss der unabhängigen Variable auf die Routenwahl ausgegangen werden.

Die Häufigkeit kritischer Situationen beeinflusst die Routenwahl, überraschenderweise, positiv. Steigt die Anzahl kritischer Situationen entlang der Route, so steigt auch die Auswahlwahrscheinlichkeit leicht. Dies wird bei der Betrachtung des Korrelationskoeffizienten der Variable deutlich (0,066). Der gefundene Zusammenhang ist zudem hochsignifikant (Sign. = 0,000). Die Odds Ratio von OR = 1,068 stützt diesen Zusammenhang. Das bereits angeführte Beispiel verdeutlicht jedoch, wie schwach die Variable die Routenwahl beeinflusst: Eine Erhöhung der Anzahl kritischer Situationen entlang einer Route um +10 % führt zu einem Anstieg der Auswahlwahrscheinlichkeit dieser Route um +0,5 %. Es ergibt sich eine Differenz der Auswahlwahrscheinlichkeit beider Routen von nur rund 1,0 %.

Die Ergebnisse der Analyse sind überraschend. Vor allem der positive Einfluss von Punkten kritischer Situationen wurde in dieser Form nicht erwartet. Inwiefern die Ergebnisse durch die Datenerhebung beeinflusst wurden und wie sie interpretiert werden könnten, wird in Kapitel 6 erörtert und diskutiert.

***m) Knotenpunkte und deren Regelung***

Knotenpunkte besitzen, in Abhängigkeit von deren Art der Regelung (rechts-vor-links vs. LSA), einen teils wesentlichen Einfluss auf die Auswahlwahrscheinlichkeit einer Route.

Es kann zunächst festgehalten werden, dass Knotenpunkte der Regelungsart „rechts-vor-links“ keinen nennenswerten Einfluss auf die Routenwahl ausüben. Dies wird zum einen an dem Korrelationskoeffizienten der Variable (0,016) deutlich. Zum anderen zeigt die Signifikanz von 0,432, dass der gefundene Zusammenhang statistisch nicht gesichert ist. Dies wird auch bei der Betrachtung des Konfidenzintervalls der Odds Ratio deutlich, welches zwischen 0,977 und 1,056 liegt. Es schließt den Wert 1 ein und deutet damit auf einen nicht signifikanten Zusammenhang hin. Ein derartiges Ergebnis wurde aufgrund der sehr ähnlichen Ausprägungen der Variable (siehe Kapitel 5.1) nicht ausgeschlossen.

Eine größere Häufigkeit von LSA-geregelten Knotenpunkten entlang einer Route wirkt sich hingegen signifikant positiv auf die Wahl einer Route aus. Der Korrelationskoeffizient der Variable ist 0,408. Dementsprechend steigen Nutzen und Wahlwahrscheinlichkeit einer Route leicht an, wenn mehr durch LSA geregelte Knotenpunkte auf einer Route liegen. Die Signifikanz von 0,000 zeigt zudem, dass der Einfluss der Variable hochsignifikant ist. Die Odds Ratio von OR = 1,504 bestätigt den signifikant positiven Zusammenhang zwischen der Variable und der Routenwahl.

Der Einfluss der Variable auf die Auswahlwahrscheinlichkeit einer Route lässt sich auch für die vorliegende Variable gut an dem Beispiel verdeutlichen: Erhöht sich die Häufigkeit von durch LSA geregelte Knotenpunkte entlang einer Route von durchschnittlich 1,0 KP/km um 50 % auf 1,5 KP/km, so erhöht sich die Wahrscheinlichkeit der Wahl dieser Route um rund 5,0 % auf 55,0 %. Es ergibt sich eine Differenz der Wahlwahrscheinlichkeit von 10,0 % zwischen beiden Routen. Eine Verringerung von LSA-geregelten Knoten entlang der Route würde hingegen zu einer Verringerung der Auswahlwahrscheinlichkeit führen. Sind auf einer der beiden Routen bspw. keine Knotenpunkte vorhanden, an denen der Verkehr durch eine LSA geregelt wird, dann verringert sich die Wahrscheinlichkeit dieser Route auf 39,8 %. Auch wenn an Knotenpunkten mit LSA häufig größere Wartezeiten entstehen, so lässt sich das Ergebnis dennoch intuitiv erklären, weil Lichtsignalanlagen bspw. die Querung von Hauptverkehrsstraßen erleichtern und damit zu einer Steigerung der (subjektiven) Sicherheit führen können. Dies könnte die Präferenz zur Nutzung von LSA-geregelten Knotenpunkten erklären, die sich bereits in der deskriptiven Datenauswertung angedeutet hatte.

#### *n) Flächennutzung*

Die Flächennutzung entlang einer Route übt einen wesentlichen Einfluss auf die Routenwahl der Radfahrenden aus. Ein hoher Grünflächenanteil entlang der Route wirkt stark positiv. Der Korrelationskoeffizient für die Variable ist mit 2,218 vergleichsweise hoch.

Dementsprechend stark wirkt sich ein hoher Grünflächenanteil entlang einer Route positiv auf den Nutzen der Route für die Radfahrer*innen und die Auswahlwahrscheinlichkeit aus. Die Signifikanz von 0,000 weist zudem auf einen hochsignifikanten Einfluss der Variable hin. Die Odds Ratio von OR = 9,188 bestätigt einen signifikant positiven Zusammenhang zwischen der Variable und der Routenwahl.

Der Einfluss der Variable auf die Wahlwahrscheinlichkeit einer Route lässt sich gut an dem genutzten Beispiel verdeutlichen: Erhöht sich der Grünflächenanteil entlang der Route von durchschnittlich 20,9 % auf 30,9 %, so erhöht sich Wahrscheinlichkeit der Wahl der Route um rund 5,5 % auf 55,5 %. Es ergibt sich eine Differenz der Wahlwahrscheinlichkeit von 11,0 % zwischen beiden Routen. Eine Erhöhung des Grünflächenanteils auf 50 % führt zu einer Erhöhung der Auswahlwahrscheinlichkeit auf rund 65,6 %. Die deskriptive Auswertung der Daten zeigte bereits auf, dass die gewählten Routen durchschnittlich größere Grünflächenanteile aufwiesen. Ein derart starker positiver Zusammenhang wurde aufgrund der deskriptiven Analyse jedoch nicht erwartet.

Die Betrachtung der Flächennutzung „Wohnen“ zeigt auf, dass höhere Anteile von Wohngebieten entlang der Route ebenfalls eine positive Wirkung auf die Routenwahl ausüben. Der Zusammenhang ist zwar nicht so stark ausgeprägt wie bei den Grünflächen, der Korrelationskoeffizient von 0,901 deutet aber dennoch auf einen mittelstarken positiven Zusammenhang hin. Dementsprechend führt eine Erhöhung des Anteils von Wohngebietsflächen entlang einer Route zu einer Erhöhung der Auswahlwahrscheinlichkeit. Aufgrund der Signifikanz (Sign. = 0,000) kann der gefundene Zusammenhang als hochsignifikant und statistisch gesichert angesehen werden. Die Betrachtung der Odds Ratio (OR = 2,463) bestätigt zudem Richtung und Signifikanz des erläuterten Zusammenhangs.

Am Beispiel der beiden konkurrierenden Routen wird deutlich, wie die Variable die Routenwahl beeinflusst: Erhöht sich der Anteil von Wohngebietsflächen entlang einer Route um +10,0 %, von durchschnittlich 30,8 % auf 40,8 %, so steigt die Wahrscheinlichkeit der Wahl dieser Route um 2,3 % auf 52,3 %. Es ergibt sich eine relativ geringe Differenz der Wahlwahrscheinlichkeit von 4,6 % zwischen beiden Routen. Eine weitere Erhöhung des Wohnflächenanteil entlang einer Route von 30,8 % auf 50,0 % führt zu einer Erhöhung der Wahlwahrscheinlichkeit auf rund 54,3 %. Der Einfluss der Variable auf die Routenwahl fällt also deutlich geringer aus, als dies bei den Grünflächen der Fall ist.

Auf Basis der deskriptiven Datenauswertung wurde bereits eine positive Wirkung von Grünflächen auf die Routenwahl vermutet. Die Bestätigung durch die multivariate Analyse ist daher nicht überraschend. Auf den positiven Einfluss von Wohngebietsflächen auf die Routenwahl hatte in dieser Form jedoch nichts hingedeutet.

### 5.2.2 Modell-Güte

In dem vorherigen Abschnitt wurden die einzelnen Einflussfaktoren betrachtet und deren Einfluss auf die Routenwahl anhand unterschiedlicher Maße (Korrelationskoeffizient, Signifikanz, Odds Ratio) quantifiziert. In den folgenden Abschnitten wird auf die Modell-Güte insgesamt eingegangen. Die Bestimmung der Gütemaße folgt den in Kapitel 4.3.2 beschriebenen Vorschriften.

**Log-Likelihood**

Um einen ersten Eindruck von der Modell-Güte zu bekommen, werden die –2LL des resultierenden Gesamtmodells der –2LL eines Null-Modells (Modell ohne Prädiktor-Variablen) gegenübergestellt. Die –2LL des geschätzten Modells ist $-2LL_{ges}$ = 11.335,176. Die – 2LL eines Null-Modells ist $-2LL_0$ = 25.589,608. Der Vergleich der beiden Werte zeigt, dass der Wert des Null-Modells deutlich über dem Wert des Gesamtmodells liegt. Das bedeutet, dass der Einbezug der Prädiktor-Variablen zu einer höheren Modell-Güte führt.

**Likelihood-Ratio-Test**

Der Likelihood-Ratio-Test ist ein wichtiger Test zur Prüfung der Modell-Güte, weil sein Ergebnis Auskunft über die Signifikanz des Gesamtmodells gibt. Die Likelihood-Ratio (Berechnung siehe Kapitel 4.3.2) beträgt im vorliegenden Fall LLR = 14.254,432.

Der $\chi^2$-Wert für $\alpha$ = 0,01 und 20 Freiheitsgrade ist laut $\chi^2$-Tabelle (siehe Anhang 8) $\chi^2$ = 37,57. SPSS bestimmt den $\chi^2$-Wert des Modells mit $\chi^2_{ges}$ = 14.254,431. Da 14.254 > 37,57 wird die Nullhypothese abgelehnt und das Modell kann als statistisch signifikant angesehen werden. Die Signifikanz des Modells wird von SPSS mit 0,000 angegeben. Damit gilt das Modell als hochsignifikant.

Es kann geschlussfolgert werden, dass das Gesamtmodell signifikant ist und der Einbezug der Variablen und der geschätzten Korrelationskoeffizienten einen signifikanten Beitrag zur Erklärung der Zusammenhänge liefert.

**Pseudo-$R^2$-Statistiken**

In Kapitel 4.3.2 wurden unterschiedliche Pseudo-R-Statistiken (McFadden-$R^2$, Cox&Snell-$R^2$, Nagelkerke's-$R^2$) beschrieben, die für die Einschätzung der Modell-Güte genutzt werden können.

Das McFadden-$R^2$ des vorliegenden Modells beträgt McF-$R^2$ = 0,557. Wie bereits in Kapitel 4.3.2 beschrieben, liegen die Werte des McF-$R^2$ in der Praxis deutlich niedriger als beim $R^2$ von Modellen der linearen Regression. Eine perfekte Anpassung, also ein Erreichen eines McF-$R^2$ = 1, gilt bei realen Daten allgemeinhin als nahezu unmöglich. Nach

Backhaus, et al. 2016 deuten bereits Werte zwischen 0,2 und 0,4 auf eine gute Modellanpassung hin. Mit einem McF-$R^2$ = 0,557 kann somit von einer sehr hohen Modell-Güte ausgegangen werden.

Als weiteres Güte-Maß kann das in Kapitel 4.3.2 beschriebene Cox&Snell-$R^2$ bestimmt werden. Das Cox&Snell-$R^2$ kann selbst bei einer perfekten Anpassung nur Werte kleiner eins annehmen, wodurch der resultierende Wert schwer zu interpretieren ist. Nichtsdestotrotz kann das Cox&Snell-$R^2$ Hinweise auf die Modell-Güte geben. In der Regel deckt das Cox&Snell-$R^2$ einen Wertebereich zwischen 0 und 0,75 ab. Werte nahe Null entsprechen einer geringen Modell-Güte. Für das vorliegende Modell wurde ein Wert von Cox&Snell-$R^2$ = 0,538 bestimmt. Damit kann von einer hohen Güte des vorliegenden Modells ausgegangen werden.

Das Nagelkerke's-$R^2$ ist ein weiteres Maß zur Bestimmung der Modell-Güte (siehe Kapitel 4.3.2). Im Gegensatz zum Cox&Snell-$R^2$ kann es auch einen Maximalwert von eins erreichen. Daher sind die Werte des Cox&Snell-$R^2$ ähnlich wie das $R^2$ bei der linearen Regressionsanalyse oder dem McF-$R^2$ zu interpretieren. Für das vorliegende Modell wurde ein Nagelkerke's-$R^2$ = 0,717 bestimmt. Damit besitzt das Modell eine hohe bis sehr hohe Güte.

**Klassifikationsstatistik**

Die Klassifikationsstatistik ist ein weiteres Maß, dass zur Beurteilung der Modell-Güte herangezogen werden kann. Sie gibt Auskunft darüber, wie exakt das geschätzte Modell die Wahl für die vorliegenden Fälle – also die Wahl/Ablehnung der Routen/Alternativen – prognostiziert, indem die Beobachtungen den Vorhersagen in der sog. *Confusion Matrix* gegenübergestellt werden. Die Klassifikationsstatistik des vorliegenden Modells ist in Tabelle *16* dargestellt.

| | | **Vorhergesagte Wahl** | | |
|---|---|---|---|---|
| | | Ja (y=1) | Nein (y=0) | **Korrekt** |
| **Beobachtete Wahl** | Ja (y=1) | 15.656 | 2.803 | 84,8% |
| | Nein (y=0) | 2.355 | 16.104 | 87,2% |
| | | | | **86,0%** |

Tabelle 16: Confusion Matrix zum vorliegenden Modell

Die Berechnung der Wahl/Ablehnung einer Route erfolgte über die berechnete Auswahlwahrscheinlichkeit für die abhängige Variable und einem Trennwert von 0,5 bzw. 50 %. Aus den Vorhersagen wurden anschließend die in Kapitel 4.3.2 beschriebenen Gütemaße berechnet.

Vom Modell werden 15.656 von insgesamt 18.459 beobachteten Fällen, in denen eine Route gewählt wurde, korrekt erkannt bzw. prognostiziert (*true positives*). Dies entspricht einem Prozentsatz von rund 84,8 % und zugleich der sog. ***true positive rate*** (bzw. *recall*). Den korrekt erkannten Fällen stehen 2.803 Fälle gegenüber, die nicht korrekt erkannt wurden. Deren Wahl wird vom Modell nicht prognostiziert, sondern abgelehnt, obwohl die Routen von den Radfahrenden gewählt wurden. Diese *false negatives* machen damit einen Anteil von 15,2 % aus.

Der Anteil der *true negatives* – also der korrekt prognostizierten Ablehnungen von Routen – liegt mit 87,2 % leicht über dem Anteil der *true positives*. Dies zeigt an, dass das Modell die Ablehnung einer Route etwas präziser prognostiziert als die Wahl einer Route. Insgesamt werden 16.104 von 18.459 nicht gewählten Routen korrekt vom Modell prognostiziert. Dieser Anteil entspricht der sog. ***true negative rate*** (bzw. *correct rejection rate*). Demgegenüber prognostiziert das vorliegenden Modell für 2.355 Routen eine Wahl, die nicht von den Radfahrenden durchgeführt wurden. Der Anteil dieser *false positives* liegt damit bei rund 12,8%.

Die ***Accuracy*** gibt den Prozentsatz der vom Modell insgesamt korrekt erkannten Entscheidungen an. Sie beträgt für das vorliegende Modell 86,0 % und ist damit als hoch einzuschätzen. Die ***Precision*** gibt das Vertrauensniveau der als *positives* klassifizierten Fälle an und bezieht alle als positiv klassifizierten Instanzen mit ein. Das vorliegende Modell weist für die *Precision* einen Wert von 86,9 % auf. Das ***F-Maß***, das die zuvor genannten Maße (*Accuracy, Recall*) kombiniert (siehe Kapitel 4.3.2) weist einen Wert von 85,9 % auf. Die berechneten Maße zeigen, dass das resultierende Modell eine durchgängig hohe Güte aufweist.

**Prognose mit unbekannten Daten**

Mit der Prognose der Routenwahl für einen Datensatz, der nicht für die Modellschätzung genutzt wurde, kann die Güte des vorliegenden Modells zusätzlich geprüft werden. Dazu wurde auf den in Kapitel 4.3.2 benannten Datensatz aus dem Projekt *RadVerS* zurückgegriffen. Dieser beinhaltete rund 4.000 Radfahrten, die mit exakt den gleichen Methoden aufbereitet wurden (siehe Kapitel 4.2), sodass eine Art Zwillings-Datensatz zur Prüfung der Modell-Güte zur Verfügung stand. Anschließend wurde das ermittelten Regressionsmodell auf diese Daten angewendet und eine Prognose für die Wahl/Ablehnung der Routen im RadVerS-Datensatz berechnet. Diese wurde anschließend mit der tatsächlichen Wahl/Ablehnung verglichen.

Die Anwendung des vorliegenden Modells auf den (für das Modell) fremden Datensatz zeigt, dass bei der Prognose der Routenwahl ähnlich gute Ergebnisse erzielt werden

wie bei der Reproduktion bzw. Prognose von Entscheidungen in dem Analyse-Datensatz. Tabelle *17* stellt die Klassifikationsstatistik der Anwendung dar.

| | | **Vorhergesagte Wahl** | | |
|---|---|---|---|---|
| | | Ja (y=1) | Nein (y=0) | **Korrekt** |
| **Beobachtete Wahl** | Ja (y=1) | 3.306 | 682 | 82,9% |
| | Nein (y=0) | 559 | 3.429 | 86,0% |
| | | | | **84,4%** |

Tabelle 17: Confusion Matrix zur Prognose der Wahl im RadVerS-Datensatz

Das Modell prognostiziert in 3.306 von insgesamt 3.988 beobachteten Fällen, in denen eine Route gewählt wurde, korrekt (*true positives*). Dies entspricht einem Prozentsatz von rund 82,9 %. Die ***true positive rate*** der Prognose der Routenwahl in den RadVerS-Daten liegt damit etwas niedriger als die im Analyse-Datensatz. Den korrekt erkannten Fällen stehen 682 Fälle gegenüber, die nicht korrekt erkannt und deren Wahl abgelehnt wurde, obwohl die Routen von den Radfahrenden gewählt wurden. Der Anteil dieser *false negatives* liegt bei rund 17,1 % und damit leicht über dem Anteil der *false negatives* im Analyse-Datensatz.

Der Anteil der korrekt prognostizierten Ablehnungen von Routen (*true negative rate*) beträgt 86,0 % und liegt damit rund 2 % über dem Anteil der *true negative rate*, die mit dem Analyse-Datensatz ermittelt wurde. Auch im Test-Datensatz liegt dieser Anteil wieder leicht über dem Anteil der *true positives*. Insgesamt werden 3.429 von 3.988 nicht gewählten Routen korrekt vom Modell prognostiziert. Demgegenüber prognostiziert das Modell für den Test-Datensatz fälschlicherweise für 559 Routen eine Wahl. Der Anteil dieser *false positives* beträgt damit rund 14,0 %.

Die ***Accuracy*** beträgt für die Anwendung des Modells auf den Test-Datensatz rund 84,4 %. Sie liegt damit zwar rund 1,8 % unterhalb der *Accuracy* des Original-Datensatzes (86,2 %), ist aber dennoch als hoch einzuschätzen. Die ***Precision*** weist für den vorliegenden Test-Fall einen Wert von 85,5 % auf. Auch dieser Wert liegt leicht unterhalb der Precision des Original-Datensatzes (87,1 %) und ist als hoch einzuschätzen. Das ***F-Maß*** weist mit 84,2 % ebenso einen hohen Wert auf (vgl. 86,0 % im Prognosefall mit dem Original-Datensatz).

Dass die Werte im Prognosefall mit dem Original-Datensatz etwas höher ausfallen, ist nicht überraschend, da das vorliegende Regressionsmodell auf diesen Daten geschätzt wurde. Die sehr geringen Differenzen zwischen den Prognosegenauigkeiten der unbe-

kannten und bekannten Daten weisen jedoch darauf hin, dass bei dem geschätzten Modell keine Überanpassung vorliegt und die Ergebnisse damit als generalisier bzw. übertragbar gelten können. Die Betrachtung der genannten Gütemaße zeigt zudem auf, dass das vorliegende Modell insgesamt über eine hohe Qualität verfügt.

## 5.3 Zusammenfassung

Die Ergebnisse der Analyse beantworten die in Kapitel 1.3 formulierten Forschungsfragen nach den Einflussfaktoren der Routenwahl und ihrer Signifikanz (Frage 1), deren Wirkrichtung (Frage 2) sowie der Einflussstärke (Frage 3). Die Antworten werden im Folgenden noch einmal kurz zusammengefasst.

Forschungsfrage 1 lautete: *„Welche Faktoren üben einen signifikanten Einfluss auf die Routenwahl von Radfahrenden in deutschen Städten (Untersuchungsraum: Dresden) aus?“*. Die Ergebnisse der vorliegenden Arbeit zeigen, dass die folgenden Faktoren die Wahl einer Route signifikant beeinflussen: Fahrtweite (Distanz), Längsneigung, Existenz von Radverkehrsinfrastruktur, Breite der Radverkehrsführung, Verkehrsstärken des Radverkehrs ($DTV_{Rad}$), Verkehrsstärken des motorisierten Individualverkehrs ($DTV_{Kfz}$), die Anzahl der Fahrstreifen des MV, die zulässige Maximalgeschwindigkeit des MV, die Oberflächenbeschaffenheit, der ruhende Verkehr, Unfallhäufigkeiten und die Häufigkeit kritischer Situationen sowie die Flächennutzung und LSA-geregelte Knotenpunkte.

Die Ergebnisse der Arbeiten zeigen jedoch auch auf, dass nicht alle Variablen innerhalb der genannten Kategorien einen signifikanten Einfluss auf die Routenwahl ausüben. Im Rahmen der Analyse konnte kein signifikanter Einfluss des Oberflächentyps „Kopfsteinpflaster“ und der Häufigkeit von rechts-vor-links-geregelten Knotenpunkte festgestellt werden. Die Signifikanzen der einzelnen Einflussfaktoren sind noch einmal in Tabelle *18* dargestellt (signifikante Variablen in Schwarz; nicht signifikante Variablen Grau).

| Variable | Korr. | Sign. | Odds | Einfluss |
|---|---|---|---|---|
| Distanz | -0,301 | 0,000 | 0,740 | – |
| Maximale Längsneigung | -0,058 | 0,000 | 0,943 | – |
| Längsneigung < 2 % | 1,373 | 0,000 | 3,947 | ++ |
| Längsneigung > 2 % | -1,084 | 0,021 | 0,338 | – – |
| Radverkehrsinfrastruktur | 4,205 | 0,000 | 67,007 | +++ |
| Breite der RVF < 1,5 m | -2,067 | 0,000 | 0,127 | – – – |
| Asphaltoberfläche | 2,210 | 0,000 | 9,114 | +++ |
| Kopfsteinpflasteroberfläche | 0,192 | 0,595 | 1,211 | o |
| $DTV_{Rad}$ > 500 | 4,158 | 0,000 | 63,914 | +++ |
| $DTV_{Kfz}$ (Mittelwert) | 0,000 | 0,379 | 1,000 | o |
| 1 Fahrstreifen MV | 1,209 | 0,000 | 3,351 | ++ |
| $v_zul_{Kfz}$ < 30 km/h | 1,140 | 0,000 | 3,126 | ++ |
| Ruhender Verkehr (Längsaufst.) | -0,152 | 0,405 | 0,859 | o |
| Unfallhäufigkeit | -0,010 | 0,000 | 0,990 | – |
| Häufigkeit krit. Situationen | 0,066 | 0,000 | 1,068 | + |
| Häufigkeit von KP mit Regelung „rvl" | 0,016 | 0,432 | 1,016 | o |
| Häufigkeit von KP mit LSA | 0,408 | 0,000 | 1,504 | + |
| Grünflächenanteil | 2,218 | 0,000 | 9,188 | +++ |
| Wohngebietsflächenanteil | 0,901 | 0,000 | 2,463 | + |

Tabelle 18: Überblick über den Einfluss der einzelnen Variablen
(von stark positiv +++ bis stark negativ – – –; o - kein Einfluss).

Forschungsfrage 2 lautete: *„Inwiefern beeinflussen diese Faktoren die Routenwahl positiv oder negativ?“*. Die Wirkrichtung der einzelnen Einflussfaktoren kann ebenfalls Tabelle *18* entnommen werden. Es lässt sich zusammenfassen, dass eine zunehmende Distanz und Längsneigungen einen negativen Einfluss auf die Routenwahl ausüben. Eine geringe Breite der Radverkehrsführung übt sich ebenso negativ auf die Wahl einer Route aus, wie eine höhere Unfallhäufigkeit entlang einer Route.

Positiv wirken hingegen geringe Längsneigungen, die Existenz von Radverkehrsinfrastruktur und das Vorhandensein anderer Radfahrender entlang einer Route. Geringe zulässige Maximalgeschwindigkeiten des Kfz-Verkehrs sowie die Existenz von nur einem Fahrstreifen für den MV wirken sich ebenfalls positiv auf die Wahl einer Route aus. Darüber hinaus üben hohe Anteile von Asphaltoberflächen, hohe Grün- und Wohngebietsflächenanteile, eine erhöhte Anzahl von Punkten mit kritischen Situationen sowie eine ansteigende Anzahl von LSA-geregelten Knotenpunkten entlang der Route einen positiven Einfluss auf die Wahl einer Route aus.

Die durchschnittlich tägliche Verkehrsstärke des Kfz-Verkehrs, der Oberflächentyp „Kopfsteinpflaster“, der ruhende Verkehr sowie die Häufigkeit von recht-vor-links-geregelten Knotenpunkten besitzen keinen (signifikanten) Einfluss auf die Routenwahl.

Forschungsfrage 3 lautete: *„Wie stark beeinflussen sie die Wahl oder Ablehnung von unterschiedlichen Routenalternativen?“*. Die Stärke der jeweiligen Einflussfaktoren fällt sehr unterschiedlich aus. Einen sehr starken (positiven) Einfluss üben vor allem das Vorhandensein von Radverkehrsinfrastruktur und anderer Radfahrender sowie hohe Anteile von Asphaltoberflächen und Grünflächen aus. Stark negative Einflüsse gehen vor allem von einer geringen Breite der Radverkehrsführungsform und hohen Längsneigungen aus. Eine zunehmende Distanz oder maximale Längsneigung entlang von Routen sowie eine hohe Unfallhäufigkeit, die Häufigkeit kritischer Situationen und LSA-geregelter Knotenpunkte entlang einer Route beeinflussen die Routenwahl hingegen nur mäßig. Richtung und Stärke der einzelnen Einflussfaktoren sind in Tabelle *18* (Spalte: Einfluss) dargestellt.

# 6. Diskussion

Um die Ergebnisse der vorliegenden Arbeit besser einschätzen zu können, werden Daten, Methoden und Ergebnisse in diesem Kapitel einer kritischen Reflektion unterzogen. Dazu werden zunächst die Ergebnisse der Arbeit interpretiert und in den Kontext der in Kapitel 3 präsentierten Forschungsarbeiten gesetzt und diskutiert. In einem nächsten Schritt werden die genutzten Primärdaten mit Ergebnissen aus einer Haushaltsbefragung verglichen sowie Resultaten anderer Forschungsarbeiten gegenübergestellt. Eine anschließende Diskussion soll helfen den Einfluss der Sekundärdaten und der Methoden auf die Studienergebnisse abzuschätzen. In der abschließenden SWOT-Analyse werden Stärken, Schwächen, Chance und Risiken der Arbeit zusammengefasst.

## 6.1 Interpretation der Ergebnisse und Einordnung in den Forschungskontext

In den folgenden Abschnitten werden die Ergebnisse der Arbeit interpretiert und in den Kontext der bereits existierenden Forschungsarbeiten gesetzt. Die Interpretation und Diskussion erfolgt – analog zu Kapitel 5.1 und Kapitel 5.2.1 – für jeden der Einflussfaktoren einzeln.

***a) Distanz***

Die Analyse des vorliegenden Datensatzes hat ergeben, dass die Distanz einer Route einen signifikanten Einfluss auf die Auswahlwahrscheinlichkeit einer Route ausübt. Dass Radfahrende kürzere Routen bevorzugen, wirkt zunächst wenig überraschend. Ein derartiger Einfluss ist intuitiv erklärbar, weil mit zunehmender Fahrtweite auch die Reisezeit und der Kraftaufwand für das Zurücklegen eines Weges ansteigt. Dies könnte im Radverkehr vor allem auf Alltagswegen unerwünscht sein, wenn Radfahrende versuchen Wege kraftschonend und zeitsparend zurückzulegen.

Ein ähnlicher Einfluss offenbarte sich auch in bereits durchgeführten Studien (siehe Kapitel 3). Die Arbeit von Menghini, et al. 2010 zeigte ebenso, dass die Proband*innen bei ihrer Routenwahl distanzempfindlich reagierten. Dass eine zunehmende Routenlänge einen negativen Einfluss auf die Auswahlwahrscheinlichkeit einer Route ausübt, wurde auch in den Arbeiten von Hood, Sall und Charlton 2011, Broach, Dill und Gliebe 2012, Casello und Usyukov 2014, Khatri, et al. 2016 Ton, et al. 2017, Chen, Shen und Childress 2017, Zimmermann, Mai und Frejinger 2017 und Ghanayim und Bekhor 2018 nachgewiesen.

Ein Ergebnis der Studie von Krizek, El-Geneidy und Thompson 2007 war zudem, dass die von den Radfahrenden gewählten Routen in der Regel nicht der kürzesten Route entsprechen. Die Gegenüberstellung der Wegelängen von gewählten Routen und erzeugten Alternativen bestätigt das auch für den vorliegenden Datensatz, in dem die gewählten Routen nur in etwa 48,4 % der Fälle kürzer waren, als die Alternativen zwischen dem Start und dem Ende der Fahrten. Obwohl die Studien auf Daten unterschiedlicher Radfahrender und mit teils unterschiedlichem Radfahrverhalten basieren, sind die Analyseergebnisse der vorliegenden Arbeit vergleichbar mit den Ergebnissen anderer Forschungsarbeiten.

***b) Längsneigung***

Die Längsneigung zeigte in den Analysen der Arbeit ebenfalls einen wesentlichen Einfluss auf die Routenwahl. Dies könnte damit erklärt werden, dass Routen, auf denen große Teile der Gesamtstrecke eine geringere Längsneigung enthalten, weniger anstrengend zurückzulegen sind und damit ein deutlich komfortableres Radfahren ermöglichen. Das Gegenteil gilt entsprechend für Routen mit höheren Anteilen großer Neigungsklassen. Aus diesem Grund sind die Ergebnisse, dass ein höherer Anteil von Streckenabschnitten mit einer Längsneigung < 2 % sich positiv auf die Wahl einer Route auswirkt und ein höherer Streckenanteil mit einer Längsneigung > 2 % die Wahlwahrscheinlichkeit verringert, intuitiv gut erfassbar.

Der gefundene Zusammenhang wurde zudem in anderen Forschungsarbeiten offengelegt (siehe bspw. Studien von Menghini, et al. 2010, Hood, Sall und Charlton 2011, Casello und Usyukov 2014, Zimmermann, Mai und Frejinger 2017 oder Chen, Shen und Childress 2017). Die Wirkung des Einflussfaktors wurde jedoch nicht von allen Studien bestätigt. So stellten Ghanayim und Bekhor 2018 bspw. keinen wesentlichen Einfluss der Längsneigung auf die Routenwahl fest. Dies könnte jedoch auf die Topographie des Untersuchungsgebietes (Tel Aviv) zurückzuführen sein (überwiegend flaches Relief). In einigen Studien, wie bspw. den Arbeiten von Khatri, et al. 2016 und Ton, et al. 2017, wurde der Einfluss nicht in die Analyse einbezogen. Gründe dafür könnten einerseits eine mangelnde Datenverfügbarkeit sein oder die Entscheidung der Autor*innen, die Längsneigung zu vernachlässigen. Die zugrundeliegende Annahme dürfte hier ebenfalls in der Topographie der Studiengebiete (z.B. Amsterdam) zu finden sein.

Der negative Einfluss der maximalen Längsneigung wirkt bei dem Vergleich und der Interpretation der Ergebnisse vergleichsweise gering. Es muss jedoch beachtet werden, dass die maximale Längsneigung nicht in Relation zur Routenlänge steht. Der Einfluss der maximalen Längsneigung ist daher nicht direkt mit dem Einfluss der Streckenanteile der

Längsneigungsklassen vergleichbar. In Kapitel 5.2.1 wurde bereits dargestellt, dass ein Anstieg der maximalen Längsneigung um +1 % bereits zu einer Verringerung der Auswahlwahrscheinlichkeit um -1,4 % führt. Angesichts der Tatsache, dass der Anteil eines solchen Streckenabschnitts im Verhältnis zur Gesamtstrecke sehr gering sein kann, muss der Einfluss der maximalen Längsneigung entlang der Routen höher eingeschätzt werden, als es der Anblick der Regressionskoeffizienten und Odds Ratios des Modells zunächst vermuten lässt.

#### *c) Radverkehrsführung*

Die Radfahrenden der Stichprobe zeigen eine starke Präferenz zur Wahl ihrer Route in Abhängigkeit von vorhandener Radverkehrsinfrastruktur. Diese ausgeprägte Präferenz zeigte sich bereits im Rahmen der deskriptiven Auswertung und wurde durch die Ergebnisse der multivariaten Analyse bestätigt.

Ein derartiges Ergebnis ist intuitiv erklärbar und wurde vor allem auf Basis des recherchierten Wissensstands erwartet. Die Ergebnisse vorangegangener Arbeiten zeigen einen ähnlichen Einfluss und es ist soweit keine Studie bekannt, in der ein negativer Zusammenhang zwischen dem Vorhandensein von Radverkehrsinfrastruktur und der Routenwahl ermittelt wurde. Ein stark positiver Einfluss wurde auch in dem Großteil der recherchierten Forschungsarbeiten gefunden (siehe Krizek, El-Geneidy und Thompson 2007, Menghini, et al. 2010, Hood, Sall und Charlton 2011, Broach, Dill und Gliebe 2012, Kang und Fricker 2013, Casello und Usyukov 2014, Khatri, et al. 2016, Chen, Shen und Childress 2017, Zimmermann, Mai und Frejinger 2017 und Ghanayim und Bekhor 2018).

In der vorliegenden Arbeit konnte die Radverkehrsführungsform jedoch nicht differenzierter betrachtet werden. Dies ist vor allem auf die Datenverfügbarkeit und den hohen Aufwand der Datenerhebung zurückzuführen, da für einen Großteil des Dresdner Verkehrsnetzes (vor allem für Strecken abseits des Hauptverkehrsnetzes) keine bzw. nur wenige Informationen zur Führungsform vorlagen. Dieser Punkt wird in Kapitel 6.2.2 noch einmal aufgegriffen und diskutiert. Diesbezügliche Analysen bleiben weiterführenden Arbeiten vorbehalten.

#### *d) Breite der Radverkehrsführung*

Die Analyse zeigte insgesamt auf, dass die Routenwahl der Radfahrenden in der Stichprobe stark durch die Breite der vorhandenen Radverkehrsinfrastruktur beeinflusst wird. Hohe Streckenanteile mit einer geringen Breite der Radverkehrsführungsform (< 1,5 m) verringern die Auswahlwahrscheinlichkeit einer Route stark.

Der negative Einfluss einer Radverkehrsführung mit eher geringer Breite wurde vor Beginn der Analyse vermutet und ist intuitiv erklärbar. Eine breite Radverkehrsinfrastruktur verringert die Flächenkonkurrenz zwischen Radfahrenden und erhöht den Abstand zu anderen Verkehrsteilnehmer*innen. Dies könnte zu einer Steigerung der objektiven und subjektiven Sicherheit der Radfahrenden führen. In diesem Zusammenhang ließe sich der negative Einfluss einer Führung mit geringer Breite gut interpretieren.

Die Ergebnisse der vorliegenden Arbeit lassen sich jedoch nur bedingt mit anderen Studien vergleichen. Das ist darauf zurückzuführen, dass nur die Arbeit von Kang und Fricker 2013 den Einfluss der Breite von Infrastruktur untersucht hat. In der Studie wurde die Breite von Fußverkehrsanalagen in die Analyse aufgenommen, wenn diese von den Radfahrenden genutzt wurden. Es zeigte sich, dass eine geringe Breite von gemeinsam genutzten Geh- und Radwegen einen negativen Einfluss auf die Routenwahl hat.

Die Studienergebnisse lassen sich demnach nicht direkt vergleichen. Sowohl die Ergebnisse der vorliegenden Studie als auch die Ergebnisse von Kang und Fricker 2013 könnten jedoch auf Flächenkonkurrenz und Nutzungskonflikte hindeuten, die mit der subjektiven und objektiven Sicherheit oder dem Komfort in Zusammenhang stehen könnten.

#### *e) Oberflächenbeschaffenheit*

Hohe Anteile einer Route mit einer als komfortabel empfundenen Oberflächenbeschaffenheit (Asphalt) beeinflussen die Routenwahl signifikant positiv. Der positive Einfluss dieser Oberfläche auf die Routenwahl ist nicht überraschend und wurde vor der Analyse angenommen.

Der Grund für den positiven Einfluss dürfte vor allem auf das Komfortempfinden der Radfahrenden zurückgehen. So steigert das Fahren auf einer glatten Oberfläche den Fahrtkomfort vermutlich deutlich gegenüber einer Fahrt auf rauer Oberfläche (z.B. Kopfsteinpflaster). Darüber hinaus ermöglicht eine glatte Oberfläche häufig höhere Fahrtgeschwindigkeiten und resultiert damit auch in geringeren Reisezeiten. Ein weiterer Zusammenhang könnte zwischen dem Sicherheitsempfinden und der Oberflächenqualität bestehen. Die Radfahrenden könnten sich auf einer gleichmäßigen Oberfläche guter Qualität deutlich sicherer fühlen, als bspw. auf einer rauen Oberfläche. Dies könnte wiederrum zu einer positiven Bewertung dieser Oberfläche und der verstärkten Nutzung von Routen führen, die hohe Streckenanteile mit einer als komfortabel empfundenen Oberflächenbeschaffenheit aufweisen.

Die Ergebnisse der vorliegenden Arbeit decken sich weitestgehend mit den Resultaten der Arbeit von Kang und Fricker 2013, in deren Analysen sich ebenfalls ein positiver

Einfluss von „guter Oberfläche“ (*good pavement condition*) auf die Routenwahl herauskristallisierte. Weitere Arbeiten, die diesen Einflussfaktor in die Analyse einbezogen, existierten zum Zeitpunkt der Niederschrift nicht.

#### *f) Radverkehrsstärken*

Höhere Werte der durchschnittlich täglichen Radverkehrsstärke ($DTV_{Rad}$) entlang einer Route üben einen starken und signifikant positiven Einfluss auf die Routenwahl der Radfahrenden im analysierten Datensatz aus.

Der stark positive Einfluss der Radverkehrsstärken auf die Routenwahl ließe sich u.a. damit erklären, dass ein Mehr an Radfahrenden entlang einer Route für ein Mehr an Sichtbarkeit des Radverkehrs selbst sorgt und so evtl. auch zu einer Steigerung des subjektiven Sicherheitsempfindens der Radfahrenden führen könnte (*safety in numbers effect*).

Aufgrund der Tatsache, dass andere Forschungsarbeiten (siehe Kapitel 3) bisher nur selten den Einfluss der Radverkehrsstärken auf die Routenwahl analysiert haben, können die vorliegenden Ergebnisse lediglich den Ergebnissen einer Forschungsarbeit gegenübergestellt werden. Aus der Studie von Koh und Wong 2013 ging ebenfalls hervor, dass Radfahrende Routen bevorzugen, auf denen weitere Radfahrende präsent sind.

Gleichzeitig muss darauf hingewiesen werden, dass die Radverkehrsstärken auch in Zusammenhang mit den Routendaten stehen. Da die aggregierten Radverkehrsmengen in Kombination mit den Werten der Dauerzählstellen für die Erzeugung der Radverkehrsstärken genutzt wurden (siehe Kapitel 4.2.2), besteht zumindest ein indirekter Zusammenhang zwischen den Routendaten und dem $DTV_{Rad}$. Da jedoch auch ein starker Zusammenhang zwischen den Zähldaten und den aggregierten Radverkehrsmengen besteht, kann der Zusammenhang, dass Radfahrende gern dort fahren, wo andere Radfahrende fahren, als gesichert angenommen werden.

#### *g) Kraftfahrzeugverkehrsstärke*

In der Analyse zeigte sich insgesamt, dass die Routenwahl der Radfahrenden in der Stichprobe nicht durch den $DTV_{Kfz}$ beeinflusst wird. Es konnte kein Einfluss der durchschnittlichen Kraftfahrzeugverkehrsstärke auf die Routenwahl nachgewiesen werden.

Das Ergebnis überrascht zunächst, da zu Beginn der Arbeit ein negativer Einfluss von steigenden Kraftfahrzeugverkehrsstärken auf die Routenwahl angenommen wurde. Hintergrund der Annahme war, dass höhere Kraftfahrzeugstärken auch mit höheren Lärm- und Schadstoffemission einhergehen und daher als negativ von den Radfahrenden empfunden werden. Offensichtlich wählten die Radfahrenden in der Stichprobe jedoch ihre

Routen nicht vorrangig anhand des Kriteriums einer niedrigen durchschnittlichen Kraftfahrzeugstärke.

Die Ergebnisse der vorliegenden Arbeit decken sich teils mit Resultaten anderer Forschungsarbeiten. Hood, Sall und Charlton 2011 fanden bspw. im Rahmen ihrer Studie ebenso keinen Effekt der Verkehrsstärken des motorisierten Verkehrs auf die Routenwahlwahrscheinlichkeit. Zu einem ähnlichen Ergebnis kommen Casello und Usyukov 2014, aus deren Analysen sich kein nennenswerter Einfluss der Kraftfahrzeugverkehrsstärke auf die Routenwahlwahrscheinlichkeit ableiten ließ.

Die Resultate anderer Arbeiten (siehe Broach, Dill und Gliebe 2012, Kang und Fricker 2013, Khatri, et al. 2016 und Zimmermann, Mai und Frejinger 2017) stehen diesen Ergebnissen jedoch entgegen. Sie kommen übereinstimmend zu dem Ergebnis, dass Radfahrende Straßen mit hohen Kraftfahrzeugverkehrsstärken des Kfz-Verkehrs meiden.

Dass der $DTV_{Kfz}$ in der vorliegenden Arbeit keinen Einfluss auf die Routenwahl ausübt, könnte auch mit den Proband*innen der Stichprobe zusammenhängen, die insgesamt als eher erfahrene Radfahrer*innen eingeschätzt werden (siehe Kapitel 6.2.1). Aufgrund dieser Tatsache könnte der Einfluss der Kraftfahrzeugstärke derart gering ausfallen.

#### *h) Fahrstreifenanzahl*

Eine geringe Anzahl an Fahrstreifen für den Kfz-Verkehr offenbarte in der Analyse einen signifikant positiven Einfluss auf die Routenwahl der Radfahrenden. Es zeigte sich eine Präferenz zur Nutzung von Routen, entlang derer dem MV nur ein Fahrstreifen zur Verfügung steht.

Dass Radfahrende Routen, auf denen für den motorisierten Verkehr nur ein Fahrstreifen zur Verfügung steht, bevorzugen, scheint intuitiv interpretierbar. So ist bspw. denkbar, dass Radfahrende nicht die Infrastruktur an sich – also das Vorhandensein eines Fahrstreifens – als vorteilhaft beurteilen, sondern vielmehr die mit ihr verbunden Eigenschaften gegenüber mehrspurigen Straßen (wie bspw. geringere Verkehrsstärken oder weniger Lärm und Emissionen).

Die Korrelationsanalyse wies keine signifikant hohe Korrelation mit z.B. dem $DTV_{Kfz}$ aus, sodass der Einfluss tatsächlich auf die Variable „Fahrstreifen“ zurückgeht. Der Zusammenhang kann aufgrund der Signifikanz des Regressionskoeffizienten zudem als gesichert angenommen werden. Tatsächlich könnten sich hinter der Variable jedoch anderen Einflussparameter verbergen, für die die Variable „Fahrstreifen“ eher eine Art Indikator darstellt.

### *i) Zulässige Höchstgeschwindigkeit des Kfz-Verkehrs*

Durch die Analyse konnte nachgewiesen werden, dass die zulässige Höchstgeschwindigkeit des motorisierten Verkehrs einen wesentlichen Einfluss auf die Routenwahl ausübt. Das Vorhandensein von Streckenabschnitten, auf denen der MV nicht schneller als 30 km/h fahren darf, beeinflusst die Routenwahl der Radfahrenden der Stichprobe signifikant positiv.

Dieses Ergebnis wird insgesamt als sehr intuitiv und gut interpretierbar angesehen. Zunehmende Geschwindigkeiten des motorisierten Verkehrs könnten bei den Radfahrenden der Stichprobe ein sinkendes Sicherheitsempfinden hervorrufen. Da die Differenzgeschwindigkeit zwischen den Radfahrenden und dem fließenden Verkehr mit zunehmender zulässiger Höchstgeschwindigkeit des MV steigt, könnte damit auch das subjektive Sicherheitsempfinden sinken. Es ist anzunehmen, dass dieser Einfluss jedoch vornehmlich bei der Führung des Radverkehrs im Mischverkehr wirkt.

Ähnliche Ergebnisse wurden auch in den Forschungsarbeiten von Casello und Usyukov 2014, Khatri, et al. 2016 und Chen, Shen und Childress 2017 erzielt, die als einzige Studien die Geschwindigkeiten des Kfz-Verkehrs als Variable in die Analysen aufnahmen. Auch in diesen Studien zeigte sich, dass Radfahrende Routen mit niedrigeren Geschwindigkeiten des fließenden MV bevorzugen.

### *j) Ruhender Verkehr*

Die Analyse offenbarte, dass der ruhendende Verkehr keinen wesentlichen Einfluss auf die Routenwahl der Radfahrenden des vorliegenden Datensatzes ausübt. Es konnte zwar ein negativer Einfluss des längs angeordneten ruhenden Verkehrs bestimmt werden, dieser ist statistisch jedoch nicht gesichert.

Dieser (nicht gesicherte) resultierende Einfluss könnte vor allem mit dem Sicherheitsempfinden der Radfahrenden im Umfeld parkender Kfz zu erklären sein. Ein- und ausparkenden Kraftfahrzeuge sowie potentielle Unfälle durch *Dooring*-Vorfälle stellen eine latente Gefahr für die Radfahrenden dar, die sich negativ auf die Wahrnehmung von längs angeordnetem ruhendem Verkehr ausüben könnte. Dies würde erklären, warum der ruhende Verkehr einen negativen Einfluss auf die Routenwahl ausübt.

In keiner der in Kapitel 3 vorgestellten Studien wurde das Vorhandensein von ruhendem Verkehr und seine Anordnung als Einflussfaktor in die Analysen einbezogen. Dies könnte unter Umständen an der fehlenden Datengrundlage bzw. aufwendigen Erhebung des Merkmals liegen (siehe auch Kapitel 6.2.2). Aufgrund der statistischen Unsicherheit des Einflusses ergänzen die Ergebnisse der vorliegenden Arbeit den bereits vorhandenen Wissensstand nur bedingt. Eine weitere Ausdifferenzierung in unterschiedliche Arten der

Anordnung des ruhenden Verkehrs (siehe Kapitel 4.2.2), die über die betrachtete Längsanordnung hinausgeht und mit einer vollumfänglichen Erhebung der Merkmale einhergehen müsste, könnte einen weiteren Beitrag zur Betrachtung des Einflusses leisten.

***l) Sicherheit***

Sowohl die Unfallhäufigkeit (objektive Sicherheit) als auch die Anzahl kritischer Situationen (subjektive Sicherheit) üben lediglich einen leichten Einfluss auf die Routenwahl der Radfahrenden der Stichprobe aus. Ein ähnliches Resultat erzielten Khatri, et al. 2016 in ihrer Studie. Sie konnten aufzeigen, dass die Unfallhäufigkeit keinen signifikanten Einfluss auf die Routenwahl der Proband*innen ausübt. Weitere in Kapitel 3 vorgestellte Studien berücksichtigen die Sicherheit nicht explizit als Einflussfaktor in deren Analysen. Kang und Fricker 2013 schließen lediglich aus den Ergebnissen ihrer Arbeit, dass bei der Nutzung spezifischer Radverkehrsinfrastruktur eine Verbindung zum Sicherheitsempfinden bestehen könnte. Sie konnten diese Annahme jedoch nicht anhand konkreter Einflussfaktoren nachweisen.

Der in der vorliegenden Arbeit ermittelte Einfluss der beiden Variablen überrascht, da vor der Durchführung der Analyse eher ein umgekehrter Einfluss vermutet wurde. Der Einfluss der Unfallhäufigkeit wurde als eher gering bzw. nicht existent angenommen. Die Annahme war, dass nur wenige Radfahrende die Unfallorte innerhalb des Stadtgebiets bei ihrer Routenwahl bedenken. Darüber hinaus geschehen an Stellen mit höheren Verkehrsmengen statistisch gesehen mehr Unfälle (Alrutz, et al. 2015), sodass als Resultat eher ein positiver Zusammenhang zwischen Routenwahl und Unfallhäufigkeit vermutet wurde.

Im Hinblick auf den Einfluss kritischer Situation wurde zu Beginn der Arbeit ein negativer Zusammenhang vermutet. Es wurde angenommen, dass Radfahrende Orte meiden, an denen vermehrt kritische Situationen entstehen. Der positive Einfluss der subjektiven Sicherheit wurde in dieser Form nicht erwartet. Eine mögliche Erklärung könnte sein, dass kritische Situationen in den Mobilitäts-Berichten (siehe Kapitel 4.2.2) vermehrt dort entstanden und berichtet wurden, wo viel (Rad-)Verkehr stattfand. Da dies vermutlich eher im Hauptverkehrsnetz der Fall ist, werden diese Punkte beim Fahren durch die Stadt zwangsläufig häufiger passiert, wenn sich Radfahrende bei ihren Fahrten durch die Stadt bspw. am Hauptverkehrsnetz orientieren. Unter diesen Annahmen ließe sich der positive Einfluss auf die Routenwahl erklären.

***m) Knotenpunkte und deren Regelung***

Knotenpunkte und deren Art der Regelung (rechts-vor-links, LSA) zeigten einen unterschiedlich starken Einfluss auf die Routenwahl. Knotenpunkte der Regelungsart „rechts-vor-links“ zeigten keinen nennenswerten Einfluss auf die Routenwahl. LSA geregelte Knotenpunkten üben einen positiven Einfluss auf die Routenwahl aus.

Dass die Häufigkeit von Knotenpunkten, die „rechts-vor-links“ geregelt sind, keinen signifikanten Einfluss auf die Routenwahl ausüben, überrascht zunächst nicht. Rechts-vor-links geregelte Knotenpunkte kommen sehr häufig im Stadtgebiet vor und es ist für Radfahrende nahezu unmöglich, derartige Knotenpunkte nicht zu passieren. Einerseits erhöhen „rechts-vor-links“ geregelte Knotenpunkte nicht unbedingt die Sicherheit beim Queren von z.B. Hauptverkehrsstraßen. Andererseits entstehen beim Passieren von Knotenpunkten durch fehlende Lichtsignalanlagen ggf. geringere oder keine Wartezeiten, was sich positiv auf die Reisezeit auswirken könnte. Die Vor- und Nachteile von „rechts-vor-links“ geregelten Knotenpunkten könnten sich daher aufheben und eventuell zu dem erzielten Ergebnis führen. Dass der bestimmte Zusammenhang statistisch nicht signifikant ist, könnte mit fehlenden Informationen zusammenhängen (siehe Kapitel 6.2.2). An dieser Stelle bedarf es weiterer Arbeiten.

An Knotenpunkten mit LSA ist es hingegen möglich, dass vergleichsweise höhere Wartezeiten entstehen. Dies gab vor der Analyse Grund zur Annahme, dass LSA geregelte Knotenpunkten einen negativen Einfluss auf die Routenwahl ausüben könnten, weil sich dadurch die Reisezeit erhöhen kann. Andererseits erleichtern Lichtsignalanlagen bspw. die Querung von Hauptverkehrsstraßen mit hohen Verkehrsstärken und könnten somit zu einer Steigerung der subjektiven Sicherheit führen. Dies könnte die Präferenz zur Nutzung von LSA geregelten Knotenpunkten, die sich bereits in der deskriptiven Datenauswertung angedeutet hat, erklären.

Dass der Einfluss von Knotenpunkten unterschiedlich ausgeprägt sein und interpretiert werden kann, zeigt auch ein Blick in die Ergebnisse vorhandener Studienergebnisse. So fanden bspw. Menghini, et al. 2010 heraus, dass eine Zunahme LSA geregelter Knotenpunkte die Routenwahl negativ beeinflusst. Ähnliche Ergebnisse erzielten Ton, et al. 2017, Ghanayim und Bekhor 2018 und Broach, Dill und Gliebe 2012, in deren Studien jeweils ein negativer Einfluss einer zunehmenden Anzahl zu passierender Knotenpunkte entlang der Routen beobachtet werden konnte. Diesen Resultaten stehen wiederrum die Resultate der Arbeiten von Khatri, et al. 2016 entgegen. In ihrer Studie wirkte sich eine steigende Anzahl von LSA geregelten Knotenpunkten entlang der Route positiv auf die Routenwahl aus. Die Autoren interpretieren dies als ein Indiz für die Erhöhung der Sicherheit durch die Nutzung von LSA beim Queren von Straßen. Auch Broach, Dill und Gliebe 2012

betonen, dass LSA geregelte Knotenpunkte in ihrer Studie durchaus einen positiven Einfluss auf die Routenwahl ausüben (z.B. beim Linksabbiegen oder Queren von Straßen mit hohen Verkehrsstärken des MV).

***n) Flächennutzung***

Die Ergebnisse der Analyse weisen eine positive Wirkung der Flächennutzung „Wohnen“ und „Grünflächen“ auf die Routenwahl aus und bestätigen damit weitgehend die Zusammenhänge, die vor der Analyse vermutet wurden.

Der positive Einfluss von Wohnflächen könnte einerseits auf die Eigenschaften von Wohngebieten zurückgeführt werden. In Wohngebieten sind die Verkehrsstärken meist reduziert und damit verbundene Emissionen (Lärm, Schadstoffe) fallen deutlich geringer aus. Darüber hinaus könnte der Einfluss jedoch auch „datenbedingt“ entstanden sein, weil sich die Start- und Zielpunkte der Routen in Wohngebieten befinden und Fahrten damit zwangsläufig durch Wohngebiete führen.

Der stark positive Einfluss hoher Grünflächenanteile entlang der Route ist dagegen deutlich intuitiver zu interpretieren. Grünflächen ermöglichen ein durchweg angenehmes Radfahren, das auf unterschiedliche Faktoren zurückzuführen ist. Entlang von Grünflächen herrschen andere Mikroklimate und im Sommer (= Zeitraum der Datenerhebung) bspw. kühlere Umgebungstemperaturen, die das Radfahren deutlich angenehmer gestalten. Darüber hinaus bieten Grünflächen meist eine Szenerie, die allgemeinhin als ästhetisch reizvoll und angenehm empfunden werden könnte (z.B. entlang des Elberadweges). Zudem ist auf einem Großteil der städtischen Grünflächen meist kein motorisierter Verkehr zugelassen, mit dem meist erhöhte Lärm- und Schadstoffemission einhergehen.

Der gefundene Zusammenhang geht in ähnlichem Maße aus der Arbeit von Koh und Wong 2013 hervor. Sie konstatieren, dass Radfahrende Routen mit einer als schön empfundenen Szenerie präferieren und ordnen diesen Einfluss vor allem dem Komfortempfinden der Radfahrenden zu. Chen, Shen und Childress 2017 kommen in ihrer Arbeit zu einem ähnlichen Ergebnis. In ihren Studienergebnissen wirken sich das Vorhandensein von Straßenbegleitgrün, das im weitesten Sinne als Grünfläche interpretiert werden kann, und die Nähe einer Route zu Grün- und Wasserflächen positiv auf die Auswahl einer Route aus. Die Ergebnisse der vorliegende Arbeit werden ebenso durch die Studienergebnisse von Ghanayim und Bekhor 2018 gestützt, die einen positiven Einfluss von Strecken in Wohngebieten, Parks und entlang der Küste feststellten.

## 6.2 Kritische Reflexion der genutzten Daten und Methoden

Die Ergebnisse von Forschungsarbeiten und deren Qualität sind stets durch die genutzten Daten und Methoden beeinflusst. Um die Ergebnisse der vorliegenden Arbeit insgesamt besser einschätzen zu können, werden in den folgenden Abschnitten die Stärken und Schwächen der genutzten Daten und Methoden erörtert.

### 6.2.1 Primärdaten

Um die Resultate der vorliegenden Arbeit für den Untersuchungsraum besser beurteilen zu können, werden die genutzten Primärdaten in den nächsten Abschnitten mit Ergebnissen der Haushaltsbefragung SrV 2018 verglichen. Sie werden darüber hinaus den Daten gegenübergestellt, die in anderen Forschungsarbeiten genutzt wurden.

**Vergleich mit SrV-Daten**

***Radfahrende***

Insgesamt haben in Dresden 1.361 Radfahrende ihre Wege mit der STADTRADELN-App aufgezeichnet. Die Anzahl der Radfahrenden, deren Wege über die App aufgezeichnet wurden, ist mit 1.361 recht hoch und liegt sogar über der Anzahl berichteter Radfahrender im SrV 2018, in dessen Rahmen 714 Radfahrende ihre Wege berichteten (siehe Abbildung *58*). Die Stichprobe der genutzten Primärdaten beinhaltet damit nahezu doppelt so viele Radfahrende wie die SrV-Stichprobe. Daher wird die Stichprobe in diesem Zusammenhang als sehr groß eingeschätzt.

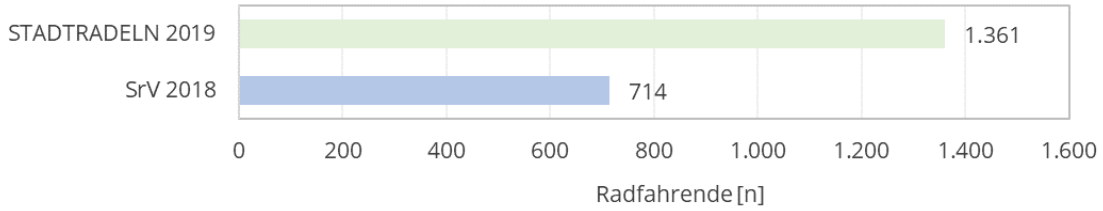


Abbildung 58: Anzahl der Radfahrenden im Vergleich

Die Anzahl der Radfahrenden in der Stichprobe lässt jedoch keine Aussage zur Qualität der Stichprobe zu. Um die Qualität der Daten besser einschätzen zu können ist es sinnvoll, die Nutzer*innengruppen näher zu betrachten. Dazu lassen sich die App-Nutzenden in Dresden nach unterschiedlichen Eigenschaften (z.B. Alter und Geschlecht) charakterisieren.

Der Altersdurchschnitt der Stichprobe liegt bei 34,5 Jahren (Mittel) bzw. 34,0 Jahren (Median). Die Radfahrenden in der Stichprobe sind durchschnittlich folglich etwas älter

als die für Dresden im Rahmen des SrV 2018 befragten Radfahrenden (Mittelwert: 32,6 und Median: 34,0). Im Vergleich zu SrV 2018 sind wesentliche Unterschiede vor allem bezüglich der jüngsten und ältesten Teilnehmer*innen zu beobachten. In Tabelle *19* sind die altersspezifischen Kennwerte der genutzten Stichprobe und der Stichprobe von SrV 2018 zusammengefasst.

| Kennwert | STADTRADELN | SrV 2018 |
|---|---|---|
| Jüngste/r | 11 | 1 |
| Älteste/r | 77 | 85 |
| Ø (Mittel/Median) | 34,5 / 34,0 | 32,6 / 34,0 |
| Standardabweichung | 10,5 | 20,6 |

Tabelle 19: Vergleich der Primärdaten

Der genannte Unterschied tritt auch bei der Betrachtung der Altersverteilung hervor (siehe Abbildung *59*). Es wird deutlich, dass sich in der für die Analyse genutzten Stichprobe weniger junge und alte Radfahrende als in der SrV-Stichprobe befinden. Dies wird vor allem auf den Datenschutz zurückgeführt, weil die Teilnahme am STADTRADELN für unter 16-jährige nicht bzw. nur mit Einwilligung der Erziehungsberechtigten erlaubt war. Im Rahmen der Erhebung von SrV 2018 wurden hingegen auch Wege von Minderjährigen durch die Eltern berichtet. Darüber hinaus wird angenommen, dass sehr alte Radfahrende vermutlich nicht am STADTRADELN teilnehmen oder während der Aktion nicht die App für die Aufzeichnung ihrer Wege genutzt haben. Dementsprechend sind sehr junge und alte Radfahrende in der genutzten Stichprobe, und damit auch in den Ergebnissen der Arbeit, unterrepräsentiert.

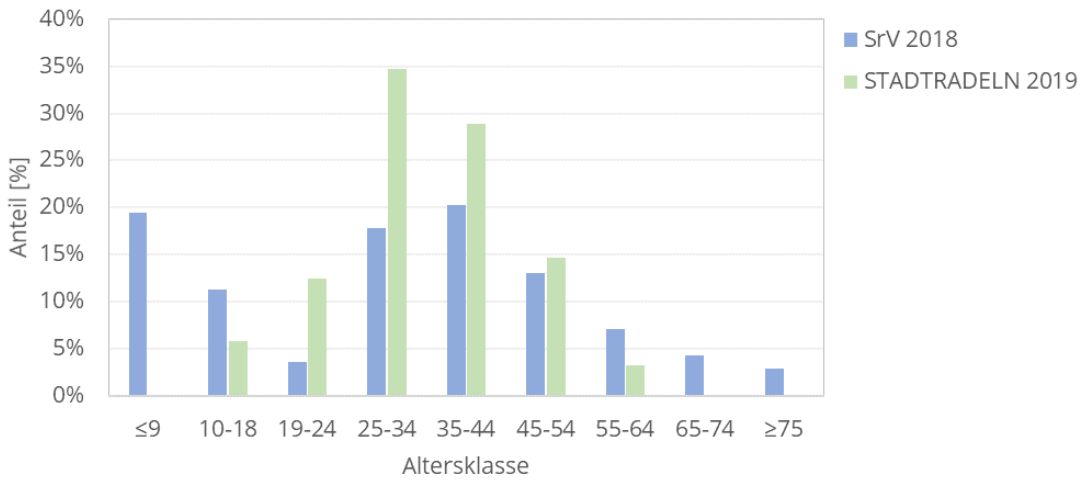


Abbildung 59: Altersverteilung der Stichproben im Vergleich

Neben der Altersverteilung kann das Verhältnis der Geschlechter als ein wichtiger Indikator herangezogen werden, um die Stichprobe zu charakterisieren. Dies kann bspw.

helfen mögliche Abweichungen im Fahrverhalten (z.B. erhöhte Streckenlängen o.ä.) der Stichproben zu erklären.

Die Geschlechterverteilung innerhalb der genutzten Stichprobe weist eine männliche Dominanz auf. Etwas mehr als die Hälfte der Radfahrenden sind Männer (55,4 %) und mehr als ein Drittel Frauen (38,6 %). Rund 6,0 % der Radfahrenden hat bei der Registrierung zur Aktion STADTRADELN kein Geschlecht angegeben. Der Vergleich mit den SrV-Daten zeigt, dass die STADTRADELN-Stichprobe stärker durch Männer dominiert wird, als dies bei den Radfahrenden im SrV 2018 der Fall war (siehe Abbildung *60*).

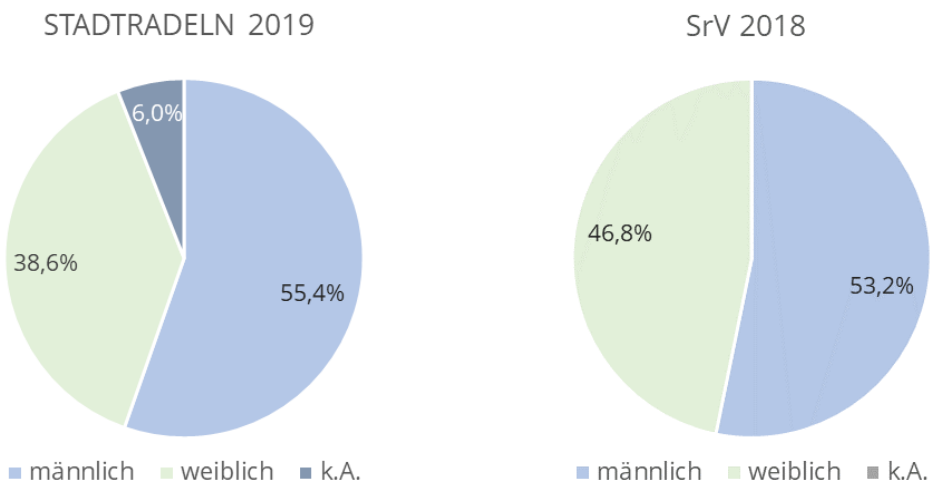


Abbildung 60: Geschlechterverteilung der Stichproben im Vergleich

Die Abweichung der Geschlechterverteilung zwischen SrV 2018 und der genutzten Stichprobe sind wahrscheinlich auf die jeweiligen Erhebungsmethoden zurückzuführen. Für die SrV-Erhebung wurden die Teilnehmenden aus zentralen Registern (z.B. Einwohnermeldeamt) gezogen. Dies kann bspw. zu einer Gleichverteilung führen, wenn Männer und Frauen gleichermaßen in der Stichprobe vertreten sein sollen.

Auf der anderen Seite lässt sich besonders bei technikaffinen Menschen eine erhöhte Nutzungsbereitschaft von Smartphone-Apps beim Radfahren beobachten. Da die Aufzeichnung der Daten über die STADTRADELN-App realisiert wurde, muss von einem sog. *self-selected sample* ausgegangen werden. In dieser sich selbst selektierenden Stichprobe sind Männer mittleren Alters meist etwas häufiger vertreten. Der Vergleich der alters- und geschlechterspezifischen Merkmalsausprägungen der genutzten Stichprobe zeigt jedoch auch, dass diese Ausprägung deutlich geringer ausfällt als bei anderen per Tracking-App erhobenen Stichproben (vgl. Strava o.ä.).

Die Frage nach der Repräsentativität der genutzten Daten muss differenziert betrachtet werden. Da die Proband*innen der Stichprobe nicht nach bestimmten Kriterien ausgewählt wurden (wie bspw. in SrV), decken sich z.B. Alters- und Geschlechterverteilung nicht mit den Daten aus SrV, die allgemein als repräsentativ gelten. Es muss jedoch immer die Frage nach der Grundgesamtheit gestellt werden sowie die Frage, „in Bezug auf was" eine Stichprobe als repräsentativ gilt. Die notwendige Stichprobengröße (also ab wann eine Stichprobe als repräsentativ gilt) kann nach Qualtrics 2021 über Formel (45) berechnet werden

$$n = \frac{\frac{z^2 * p\,(1-p)}{e^2}}{1 + \frac{z^2 * p(1-p)}{e^2 * N}} \tag{45}$$

mit *n* als Stichprobengröße, *N* als Grundgesamtheit (z.B. 563.000 für alle Einwohner Dresdens), *z* als Vertrauensniveau (z.B. 1,96 bei einem Konfidenzniveau von 95 %), *e* als Fehlerspanne (0,05) und *p* als Standardabweichung (z.B. 0,5). Legt man alle Dresdner Einwohner*innen als potentielle Radfahrende zugrunde – was in diesem Sinne sicher nicht korrekt wäre, weil nicht alle Dresdener Bürger*innen auch Radfahrer*innen sind – so läge die Stichprobe mit 1.361 Radfahrenden noch weit über der berechneten notwendigen Stichprobengröße von n = 384. Diese Annahme wäre statistisch gesehen sogar tragbar, weil bei der Analyse der Routenwahl nicht weiter nach Alter und Geschlecht unterschieden, sondern die Routenwahl eines „durchschnittlichen Radfahrenden" in Dresden analysiert wurde. Andererseits sind Unterschiede bei der Routenwahl von Kinder, jungen Erwachsenen und älteren Menschen sowie zwischen den Geschlechtern durchaus denkbar. Für eine detaillierte Betrachtung einzelner Nutzergruppen müsste die Stichprobengröße aber deutlich erhöht werden.

Es kann resümiert werden, dass der genutzte Datensatz und die Stichprobengröße eine Stärke der Arbeit darstellen. Gleichzeitig weichen Alters- und Geschlechterverteilung der Proband*innen jedoch leicht von den in SrV erhobenen Werten ab. Chancen, die Eigenschaften der Stichprobe näher an die Verteilung in den SrV-Daten zu bringen, bestünden bspw. in der Gewichtung der Stichprobe oder der Anwendung entsprechender Filterprozesse.

***Fahrten***

Im Rahmen der Analyse konnte mit knapp 18.459 Fahrten eine große Anzahl von Radfahrten genutzt werden. Dies entspricht in etwa der 9-fachen Menge an Radfahrten, die im SrV 2018 für Dresden berichtet wurden (2.051 Fahrten mit dem Rad). Abbildung *61* stellt die Werte grafisch gegenüber. Auch wenn der Umfang der beiden Stichproben nicht

direkt vergleichbar ist, weil im Rahmen von SrV das Mobilitätsverhalten an einem Tag abgefragt wird (Stichtagsbefragung), so verdeutlicht der Vergleich dennoch, dass es sich bei der genutzten Stichprobe um einen sehr umfangreichen Datensatz handelt.

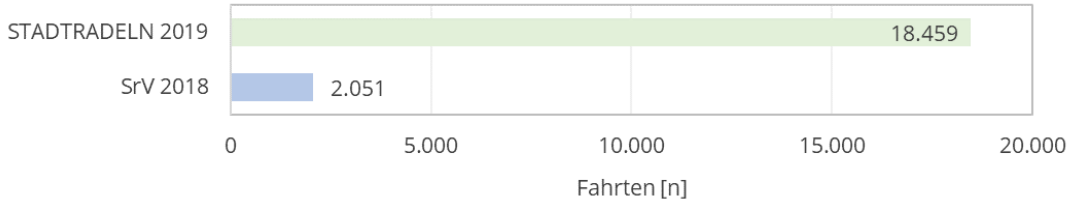


Abbildung 61: Fahrtenanzahl im Vergleich mit SrV 2018

Die Gesamtstrecke, die während des Erhebungszeitraums aufgezeichnet wurde, beträgt rund 86.500 km. Auch in dieser Hinsicht zeigt sich eine Stärke des genutzten Datensatzes. Abbildung *62* verdeutlicht, dass im Rahmen der Erhebung die ca. 13-fache Strecke (im Vgl. zu SrV) aufgezeichnet und für die Analyse genutzt werden konnte.

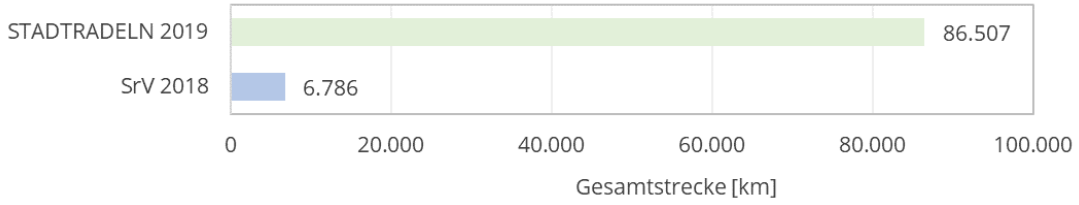


Abbildung 62: Gesamtstrecke im Vergleich mit SrV 2018

Um die Fahrtendaten zu validieren, können die Kennwerte zu den Fahrtweiten, Geschwindigkeiten und zur Fahrtdauer herangezogen werden. Die mittlere Fahrtweite der zurückgelegten Wege beträgt in den erhobenen GPS-Daten 4,7 km und liegt damit deutlich über den Werten von SrV 2018 (3,4 km). Die App-Nutzenden der Aktion STADTRADELN legten im Durchschnitt folglich längere Wege zurück, als jene Radfahrer*innen der SrV-Stichprobe. Dies zeigt sich auch bei dem Vergleich der Fahrtweitenverteilung (siehe Abbildung *63*). Während bspw. in den SrV-Daten 80 % aller Fahrten nicht länger als 5 km sind, sind im STADTRADELN-Datensatz nur knapp 62,4 % aller Fahrten bis zu 5 km lang. Die deutlich längeren Wege könnten darauf zurückzuführen sein, dass es sich bei den Teilnehmenden um passionierte Radfahrer*innen handelt, die alltäglich mit dem Fahrrad unterwegs und körperlich fit sind und somit auch längere Wege beim Radfahren in Kauf nehmen.

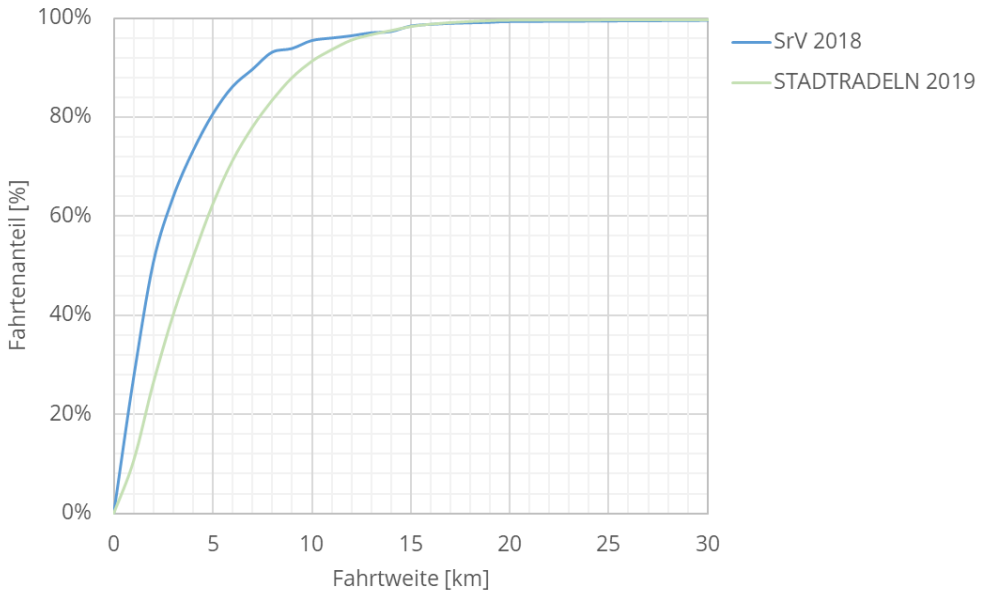


Abbildung 63: Fahrtweitenverteilung im Vergleich

Die Geschwindigkeiten und Fahrtdauern der zurückgelegten Fahrten deuten zudem darauf hin, dass es sich bei den Radfahrenden in der genutzten Stichprobe um „fitte Alltagsradler*innen“ handelt. So fällt bspw. die durchschnittliche Fahrtdauer in der Stichprobe mit 15 Minuten (Mittelwert) bzw. 12,8 Minuten (Median) im Vergleich zu 17,5 Minuten (Mittelwert) bzw. 15,0 Minuten (Median) bei den Radfahrten in SrV deutlich niedriger aus.

| | **STADTRADELN** | **SrV 2018** |
|---|---|---|
| Minimum | 6,0 | 1,0 |
| Mittelwert | 18,5 | 11,5 |
| Median | 18,3 | 12,0 |
| Maximum | 37,9 | 37,8 |
| Streuung | 32,0 | 36,8 |
| Standardabweichung | 4,0 | 5,3 |

Tabelle 20: Kennwerte der Geschwindigkeiten im Vergleich

Dies lässt auf deutlich höhere Fahrtgeschwindigkeiten schließen, die sich auch durch die Daten bestätigen lassen (siehe Tabelle *20*). Die Radfahrenden in der genutzten Stichprobe waren bei ihren Fahrten demnach deutlich schneller unterwegs als die Radfahrenden, die bei SrV ihre Fahrten berichteten. Auf der anderen Seite ist bei dem direkten Vergleich der Ergebnisse Vorsicht geboten, weil die unterschiedlichen Erhebungsarten einen starken Einfluss auf die Werte ausüben können (z.B. Unter/Überschätzung von Wegelängen und Reisezeiten durch die Befragten).

Die Frage nach der Repräsentativität der Fahrten-Daten muss, ebenso wie bei den Proband*innen, differenziert betrachtet werden. Für einen Vergleich wird die folgende vereinfachte Annahme getroffen: Bei 563.000 Einwohner*innen der Stadt, einer durchschnittlichen täglichen Wegeanzahl pro Einwohner von 3,4 Wegen/Tag sowie einem Radverkehrsanteil von 18 % werden an einem durchschnittlichen Tag rund 345.000 Radfahrten in Dresden durchgeführt. Die durchschnittliche Fahrtenanzahl beträgt im vorliegenden Datensatz rund 879 (18.459 Fahrten / 21 Tage). Sie stellen damit nur einen Bruchteil der täglich stattfindenden Fahrten dar. Die Berechnung der notwendigen Stichprobengröße (siehe Formel (45)) ergibt bei einem Konfidenzniveau von 95 % und einer Fehlerspanne von 5 % einen Wert von n = 380. Damit läge die Stichprobe über der berechneten notwendigen Stichprobengröße.

Es gilt jedoch auch an dieser Stelle weiter zu unterscheiden. Unter der oben beschriebenen Annahme sowie der Tatsache, dass nur ein durchschnittlicher Radfahrender in Dresden betrachtet wird, würde die Repräsentativität als gesichert gelten. Andererseits würde die bereits beschriebene Differenzierung nach Nutzer*innengruppen (z.B. nach Alter und Geschlecht) die Repräsentativität aufheben. Die aggregierte Betrachtung eines durchschnittlichen Radfahrenden sichert gewissermaßen die Güte. Für eine detailliertere Betrachtung müsste die Stichprobengröße jedoch deutlich vergrößert werden.

Es lässt sich zusammenfassen, dass die Größe des genutzten Datensatzes generell eine Stärke der Arbeit darstellt. Die Eigenschaften der Fahrten deuten jedoch auch auf eine bestimmte Nutzer*innengruppe hin, die als „fitte Alltagsradler*innen“ bezeichnet werden könnten. Es bleibt zu diskutieren und analysieren, inwiefern sich deren Routenwahlverhalten von dem anderen Nutzer*innengruppen unterscheidet.

### Vergleich mit anderen Forschungsarbeiten

Die Betrachtung der Primärdaten zeigt auf, dass die für die vorliegende Arbeit genutzte Stichprobe mit 1.361 Proband*innen vergleichsweise groß ausfällt. Die Analysen der meisten anderen Forschungsarbeiten basieren auf Datensätzen, die deutlich weniger Proband*innen beinhalteten (siehe Tabelle *21*). Ausnahmen stellen die Arbeiten von Menghini, et al. 2010, Khatri, et al. 2016 und Ton, et al. 2017 dar, in deren Stichproben teils doppelt so viele Radfahrer*innen enthalten waren.

Im Rahmen des Forschungsprojekts MOVEBIS wurde begleitend zur Aktion STADTRADELN eine Umfrage unter den Teilnehmer*innen durchgeführt (siehe Lißner, von Harten und Huber 2021). Die Ergebnisse der Umfrage zeigen auf, dass es sich bei den Radfahrenden der Aktion STADTRADELN in der Regel um Alltagsradfahrer*innen handelt. Es kann

daher davon ausgegangen werden, dass die in der vorliegenden Arbeit analysierte Routenwahl die Routenwahl von Alltagsradfahrer*innen widerspiegelt.

| Studie | Proband*innen | | | Fahrten |
|---|---|---|---|---|
| | Anzahl | Alter | Geschlecht | |
| Krizek et al. (2007) | N = 142 | 14-79 Jahre | ♂57% ♀43% | 142 |
| Menghini et al. (2010) | N ≤ 2.045 | k.A. | k.A. | 2.498 |
| Hood et al. (2011) | N = 366 | 14-79 Jahre | ♂79% ♀21% | 3.034 |
| Broach et al. (2012) | N = 154 | 25-64 Jahre (89%) | ♂79% ♀21% | 1.449 |
| Kang & Fricker (2013) | N = 178, 100% Stud. | 18-30 Jahre | ♂75% ♀24%, | 931 |
| Koh & Wong (2013) | N = 276 | 15-49 Jahre (73%) | ♂50% ♀50% | 276 |
| Casello & Usyukov (2014) | N ≈ 400, erfahrene Radf. | k.A. | k.A. | 724 |
| Khatri et al. (2016) | N = 1.866, Bike-Sharing | k.A. | k.A. | 9.101 |
| Ton et al. (2017) | N ≤ 3.045 | 31-64 Jahre (80%) | k.A. | 3.045 |
| Chen et al. (2017) | N = 197, erfahrene Radf. | 10-61 Jahre (72%) | k.A. | 2.922 |
| Zimmermann et al. (2017) | N = 103 | >26 Jahre (81%) | ♂74% ♀26% | 648 |
| Ghanayim & Bekhor (2018) | N = 221 | <40 Jahre (70%) | ♂73% ♀27% | 545 |
| Vorliegenden Arbeit | N = 1.361, Alltags-Radf. | 16-77 Jahre | ♂59% ♀41% | 18.459 |

Tabelle 21: Vergleich der Primärdaten (k.A. – keine Angabe)

Demgegenüber beinhalteten die Stichproben der meisten anderen Forschungsarbeiten meist Radfahrer*innen einer bestimmten Nutzer*innengruppe bzw. Radfahrende mit speziellen Charakteristika. Als Beispiele können die Arbeiten von Casello und Usyukov 2014 und Chen, Shen und Childress 2017) angeführt werden, in denen vor allem Daten von sehr erfahrenen Radfahrenden erhoben wurden. In der Arbeit von Kang und Fricker 2013 befanden sich hingegen nur Student*innen in der Stichprobe und bei Khatri, et al. 2016 wurden Daten von Bike-Sharing-Nutzer*innen verwendet. Aus vielen der recherchierten Forschungsarbeiten geht jedoch nicht eindeutig hervor, um was für ein Nutzer*innen-Kollektiv es sich handelt.

Im Rahmen der Betrachtung der Altersverteilung innerhalb der Stichproben sind nur geringe Unterschiede zwischen der Stichprobe der vorliegenden Arbeit und der Stichproben anderer Forschungsarbeiten festzustellen. In den Stichproben der meisten Studien ist eine vergleichsweise hohe Streuung des Alters zu beobachten. Jugendliche und junge Erwachsene sind ebenso Teil der meisten Stichproben wie Menschen gehobenen Alters (siehe Tabelle 21).

Deutliche Unterschiede sind hingegen bei der Gegenüberstellung der Geschlechterverteilung zu beobachten. Abgesehen von der Tatsache, dass in vielen Arbeiten keine Geschlechterverteilung festgestellt werden konnte, sind die Stichproben in den meisten der vorangegangenen Studien stark männlich dominiert (siehe Tabelle 21). Das unausgeglichene Geschlechterverhältnis ist jedoch nicht zwangsläufig als negativ zu beurteilen

(z.B. wenn es die Geschlechterverteilung der Grundgesamtheit exakt widerspiegelt). Es bedeutet jedoch auch, dass die Routenwahl von Radfahrer*innen nicht ausreichend berücksichtigt wurde. Mit einem Geschlechterverhältnis von 59 % (männlich) zu 41 % (weiblich)[8] kann für die vorliegende Arbeit von einer ausreichend starken Berücksichtigung aller Geschlechter ausgegangen werden. Lediglich die Studien von Krizek, El-Geneidy und Thompson 2007 und Koh und Wong 2013 nutzen Daten, in denen das Geschlechterverhältnis ausgeglichener ist. Beiden Studien ist jedoch die geringe Anzahl an Proband*innen und Fahrten gemein.

Mit über 18.000 Fahrten wird die für die vorliegende Arbeit genutzte Datenbasis als sehr umfangreich eingeschätzt. Dies zeigt auch die Gegenüberstellung mit den vorangegangenen Forschungsarbeiten, die teils sehr wenige Fahrten für ihre Analyse genutzt haben (siehe Tabelle 21).

Es lässt sich festhalten, dass die erhobenen Primärdaten eine vergleichsweise hohe Güte erreichen. Sie enthalten Daten von 1.361 Radfahrerenden und damit deutlich mehr unterschiedliche Nutzer*innen, als in den meisten anderen Studien. Darüber hinaus handelt es sich um Alltagsradfahrer*innen aller Altersklassen, deren Geschlechterverhältnis nicht stark asymmetrisch verteilt ist. Die Stichprobe enthält mit über 18.000 Fahrten zudem eine große Anzahl von Fahrten, die in keiner anderen Forschungsarbeit erreicht wurde.

### 6.2.2 Sekundärdaten

Im Rahmen der Studie wurden zahlreiche Sekundärdaten verarbeitet und genutzt. Gleichzeitig konnten jedoch nicht alle möglicherweise relevanten Daten in die Analyse integriert werden. Dies ist vor allem auf die Datenverfügbarkeit und den Aufwand der Erhebung und Aufbereitung der entsprechenden Daten zurückzuführen.

Im Zuge der Arbeiten wurde die Entscheidung getroffen, vornehmlich Daten für das Hauptverkehrsnetz der Stadt aufzubereiten, da sich der Radverkehr auf den Streckenabschnitten dieses Netzes konzentriert und eine Vollerhebung sehr aufwendig gewesen wäre. Dies führte im Folgenden jedoch dazu, dass die Eigenschaften der Routen nicht für jede Route oder Alternative vollständig berechnet werden konnten. Es ist daher nicht auszuschließen, dass die fehlenden Informationen einen Einfluss auf die Ergebnisse der Arbeit ausüben. Für eine 100 % korrekte Berücksichtigung müssten daher noch weitere Sekundärdaten (vor allem für das Nebennetz) erhoben werden.

[8] Bereinigte Werte ohne „k.A."

Die fehlenden Informationen im Nebennetz wirkten sich auf die Ausprägung der Routeneigenschaften aus, sodass viele Einflussfaktoren nicht, wie ursprünglich angedacht, in aller Tiefe untersucht werden konnten. Die Radverkehrsführung kann als ein Beispiel dafür herangezogen werden. Aufgrund der Tatsache, dass durchschnittlich für große Teile der Routen/Alternativen keine Informationen zur Radverkehrsführungsform vorlagen und die Werte der ursprünglich vorgesehenen und sehr fein differenzierten Führungsformen in ihrer Ausprägung sehr stark streuten, mussten die unterschiedlichen Variablen aggregiert werden, damit sie für die Analyse genutzt werden konnten. Dies ist bedauerlich, da so keine detaillierten Informationen zum Einfluss der unterschiedlichen Führungsformen erarbeitet werden konnten. Diese Kritik kann auf nahezu alle Variablen ausgeweitet werden.

Zur Abbildung der objektiven Sicherheit wurden die polizeilich erfassten Unfälle genutzt. Da die Unfalldaten sehr umfangreich sind, könnte eine weitere Differenzierung (z.B. nach Art oder Schwere der Unfälle) aufschlussreich sein. Es könnte zudem untersucht werden, ob eine anderweitige Berücksichtigung der Unfallanzahl (z.B. durchfahrene Unfallschwerpunkte statt Anzahl der Unfälle/km) sinnvoll wäre.

Um die subjektive Sicherheit abbilden zu können, wurden die im Projekt *RadVerS* berichteten kritischen Situationen herangezogen. Es bleibt jedoch zu hinterfragen, ob diese Daten die subjektive Sicherheit hinreichend genau abbilden können. Orte, an denen kritische Situationen berichtet wurden, müssen nicht zwangsläufig auch Orte sein, an denen sich die Radfahrenden unsicher fühlen. Darüber hinaus wird die Stichprobengröße ($n = 407$) im Verhältnis zu den genutzten Fahrten ($n > 18.000$) als relativ klein eingeschätzt. Die Orte „subjektiver Unsicherheit“ könnten somit weniger aussagekräftig sein als angenommen. Zudem muss angemerkt werden, dass vsl. an jenen Orten mehr kritische Situationen entstehen, wo mehr Rad gefahren wird. Dies könnte auch den positiven Einfluss der Variable erklären. Aus diesem Grund sollten andere Datenquellen, die bspw. eine Bewertung der subjektiven Sicherheit für einzelne Strecken und Knotenpunkte zulassen, für eine tiefergehende Analyse herangezogen werden.

Der Einfluss des Sicherheitsraums (Abstand zum fließenden MV) auf die Routenwahl konnte aufgrund der geringen Anzahl an Merkmalsausprägungen nicht in der Analyse berücksichtigt werden. Ein möglicher Lösungsansatz wäre auch hier, weitere Werte im Nebennetz zu erheben.

Eine ähnliche Herausforderung bestand bzgl. der Integration des $DTV_{Kfz}$. Für diese Variable lagen einerseits nur Werte für das Hauptverkehrsnetz vor. Darüber hinaus stammen die Werte nicht nur aus dem Zeitraum der Datenerhebung der Radfahrten (2019), sondern aus unterschiedlichen Jahren (2010-2019), die von der Stadt aggregiert wurden,

um einen stadtweiten $DTV_{Kfz}$ zu ermitteln. Es musste an dieser Stelle somit die Annahme getroffen werden, dass sich der $DTV_{Kfz}$ zumindest nicht wesentlich verändert hat. In Anbetracht des langen Zeitraums wird diese Annahme als fragil eingestuft.

Die Berücksichtigung des ruhenden Verkehrs stellte eine besondere Herausforderung dar. Stellflächen des ruhenden Verkehrs sind zwar stadtweit vorhanden, sie konzentrieren sich augenscheinlich jedoch weniger entlang des Hauptverkehrsnetzes, sondern kommen vielmehr im Nebennetz vor. Dies spiegelt sich auch in den Routeneigenschaften wider, in denen der ruhende Verkehr ein eher seltenes Ereignis darstellte. Diese Unschärfe führte in den Daten zu einer starken Streuung und relativ vielen Ausreißern, sodass nicht alle Daten für die Analyse genutzt werden konnten. Für eine bessere Berücksichtigung des ruhenden Verkehrs könnte eine Erhebung im Nebennetz daher sehr zweckdienlich sein.

Um den Einfluss der Radverkehrsmengen auf die Routenwahl zu analysieren, mussten Daten zu den Radverkehrsstärken in die Analyse integriert werden. Aufgrund der Datenverfügbarkeit (es existiert derzeit keine Datenquelle, die Aufschluss über stadtweite Radverkehrsmengen gibt) wurden die Primärdaten zu Radverkehrsmengen aggregierten und auf den $DTV_{Rad}$ skaliert. Von der Nutzung ein und derselben Datenbasis sollte jedoch prinzipiell abgeraten werden, weil sie zu einem positiven Einfluss des Radverkehrs auf die Routenwahl führen könnten. Die Verkehrsmengen basieren zum Teil auf den Fahrten der einzelnen Routen, die untersucht werden. Andererseits ist dies nur für Streckenabschnitte mit geringen Verkehrsmengen problematisch, auf denen die zu untersuchenden Routen einen wesentlichen Anteil der Verkehrsmengen ausmachen. Dieser Fall liegt im Datensatz meist nur zu Beginn/Ende einer Route (in abgelegenen Gebieten) vor. Eine Möglichkeit zur Vermeidung der geschilderten Problematik bestünde in der Nutzung anderweitiger Radverkehrsdaten. Derzeit sind jedoch keine Datensätze bekannt, die den Radverkehr und seine Verteilung derart detailliert abbilden und Aufschluss über die Verkehrsstärken im Verkehrsnetz geben.

Im Rahmen der Analyse wurde die Distanz als ein Einflussfaktor der Routenwahl analysiert. Dies ist auf die mangelnde Vergleichbarkeit der Reisezeiten zwischen den Originalrouten und den Routenalternativen zurückzuführen. Da die Alternativen algorithmisch erzeugt wurden und mittlere Reisezeiten berechnet werden, können diese zwangsläufig nicht mit den Reisezeiten übereinstimmen, die durch die Radfahrenden auf diesen Alternativen realisiert würden. Da die Distanzen direkt vergleichbar sind, wurden sie in die Analyse aufgenommen. Eine Integration der Reisezeiten wäre jedoch wünschenswert und aufschlussreich.

Abseits der in die Analyse integrierten Variablen existieren zahlreiche Einflussfaktoren (siehe Kapitel 3), die aufgrund der Datenverfügbarkeit oder des hohen Erhebungsaufwands nicht berücksichtig werden konnten. So konnte z.B. nicht der Einfluss von Abbiegevorgängen, Fahrtrichtungsfreigaben oder an Knotenpunkten entstehender Wartezeiten untersucht werden, weil dafür komplexe und sehr detaillierte Netzmodelle notwendig sind. In einigen Forschungsarbeiten wurde zudem die „Szenerie“ als Einflussfaktor untersucht (siehe Kapitel 3), für den in der vorliegenden Arbeit die Flächennutzung als Indikator genutzt wurde. Da Ästhetik einer Landschaft oder Szenerie hochgradig subjektiv ist, sollte das Vorgehen als Annäherung angesehen und auch dementsprechend interpretiert werden.

### 6.2.3 Methoden

Für die Durchführung der Analysen wurde eine Vielzahl unterschiedlicher Verfahren erarbeitet und genutzt. Die in der Arbeit verwendeten Methoden haben sich für die Durchführung der Arbeit als adäquat erwiesen. Sie weisen neben spezifischen Stärken teilweise jedoch auch Schwächen auf. Diese sollen in den folgenden Abschnitten diskutiert werden.

Die Primärdatenerhebung wurde im Rahmen einer seit elf Jahren bestehende Kampagne (Aktion STADTRADELN) durchgeführt. Dadurch konnten sehr viele Radfahrer*innen angesprochen und zur Datenerhebung bewegt werden. Die realisierte Stichprobe von mehr als 1.300 Radfahrer*innen und über 18.000 nutzbaren Radfahrten ist an dieser Stelle positiv hervorzuheben.

Die Motivation der Teilnehmer*innen bestand während der Datenerhebung maßgeblich in dem Einsparen von $CO_2$ (ggü. der Nutzung eines Pkw). Es wird daher angenommen, dass diese Motivation evtl. eine bestimmte Nutzer*innengruppe bzw. Personen aus einem bestimmten Milieu anspricht. Auf der anderen Seite wurde die Kampagne über unterschiedliche Kanäle kommuniziert und ist so gestaltet, dass sie möglichst alle Bürger*innen anspricht. Eine zum STADTRADELN parallel durchgeführte Befragung im Jahr 2020 ergab, dass sich der Teilnehmerkreis zu großen Teilen aus Personen zusammensetzt, die regelmäßig das Fahrrad nutzen (Lißner, von Harten und Huber 2021). Es handelt sich offensichtlich um Alltagsradfahrer*innen, die nicht, wie anfangs befürchtet, nur am Wochenende auf das Fahrrad steigen, um lange Freizeitfahrten durchzuführen (rund 88 % aller Fahrten wurden an Werktagen zurückgelegt).

Aufgrund von softwarebedingten Problemen der Smartphone-App (sie funktionierte vor allem auf Smartphones mit älteren Betriebssystemen nicht immer einwandfrei) konnten nicht alle Radfahrer*innen an der Erhebung teilnehmen. Anpassungen an der App (für ältere Betriebssysteme) hätte an dieser Stelle evtl. zu einer noch größeren Stichprobe führen können. Es ist jedoch fraglich, ob dies qualitativ zu anderen oder „besseren" Ergebnissen geführt hätte.

Neben der Datenerhebung war die Datenverarbeitung (insbesondere die Validierung der erhobenen Daten) von besonderer Relevanz. Eine manuelle Plausibilisierung der Routendaten wäre eine Möglichkeit gewesen, um nicht korrekt erfasste Fahrten (z.B. Fahrten mit anderen Verkehrsmitteln oder starken Signalabweichungen) zu erkennen und zu entfernen. Eine derartige Plausibilisierung würde in der Regel durch einen visuellen Abgleich geschehen, der bei der vorliegenden Datenmenge von initial über 25.000 Fahrten nicht realisierbar gewesen wäre. Stattdessen wurden unterschiedliche Methoden zur automatischen Aufbereitung genutzt. Der Vorteil einer automatischen Verarbeitung ist, dass eine Vielzahl von Parametern in die Prüfung eingeht (Geschwindigkeiten, Beschleunigungen, Trajektorien, Signalqualität usw.) und nicht nur der Routenverlauf (Vgl. visueller Abgleich). Mithilfe der genutzten Verfahren konnte zudem der Datenverlust minimiert werden. In anderen Arbeiten wurden im Rahmen der Datenverarbeitung meist starke Filterkriterien genutzt (bspw. Distanz- oder Zeitfilter). Dies führt in der Regel dazu, dass viele Fahrten nicht im Datensatz verbleiben und daher auch nicht genutzt werden können (z.B. wenn ein langer GPS-Track mehrere Fahrten beinhaltet oder einen Aufenthalt am Arbeitsplatz) und so Daten verloren gehen, die eigentlich genutzt werden könnten.

Dies wurde in der vorliegenden Arbeit durch mehrere Schritte vermieden. Zum einen wurden fehlerhafte Werte, die einzelne GPS-Punkte betrafen, korrigiert oder herausgefiltert. Eine derart detaillierte Bearbeitung findet i.d.R. nicht statt, obwohl bspw. Signalsprünge und Signalbeugung bei den GPS-Empfangsgeräten einen durchaus großen Einfluss auf den resultierenden Verlauf einer Route und die anschließenden Datenverarbeitungsschritte ausüben. Die detaillierte Aufbereitung der Daten konnte demnach dazu beitragen, die Genauigkeit, z.B. des Routenverlaufs, deutlich zu erhöhen. Es wurden darüber hinaus zwar auch starke Filterkriterien angewendet, um bspw. Fahrten mit großen Datenlücken oder geringen Genauigkeiten zu entfernen. Dies wurde in Anbetracht der großen Stichprobe und der resultierenden höheren Datengüte jedoch als vertretbar angesehen.

Die Genauigkeit des für die Verkehrsmittelerkennung genutzten Verfahrens hat mutmaßlich den größten Einfluss auf das Ergebnis der Primärdatenverarbeitung. Die Erkennung wurde so kalibriert, dass möglichst alle Fahrten aus dem Datensatz herausgefiltert

werden, bei denen es sich nicht um Radfahrten handelt. Bei der Erkennung musste eine Art Optimierungsproblem gelöst werden, bei dem ein Verzicht auf Radfahrten als weniger problematisch erachtet wurde, als der Einschluss aller Radfahrten unter der Prämisse, dass Fahrten mit anderen Verkehrsmittel ebenfalls im Datensatz verbleiben. Im Rahmen der Verkehrsmittelerkennung wurden daher nur knapp 90 % der Radfahrten erkannt und in die weiteren Berechnungsschritte überführt (es wurden einige hundert Radfahrten fälschlicherweise als andere Verkehrsmittel erkannt und herausgefiltert). Der Verlust dieser Fahrten wurde in Anbetracht der Stichprobengröße und der resultierenden Datengüte jedoch als vertretbar eingestuft.

Die resultierenden Fahrten wurden mittels Map Matching den Strecken im Verkehrsnetz zugewiesen. Dazu wurde ein komplexes, aber etabliertes Verfahren gewählt und an die Ansprüche des Vorhabens angepasst, sodass die Zuweisung von Routen zum Verkehrsnetz mit einer sehr hohen Genauigkeit erreicht werden konnte.

Als größte Fehlerquelle wurde im Rahmen der Fehleranalyse das Netzmodell identifiziert. So traten bspw. Fehler auf, wenn im Angebotsnetz Streckenabschnitte nicht eindeutig über Knotenpunkte verbunden waren (kleine Lücken im Netz). Dies führte zwangsläufig zu Fehlern bei der Zuweisung, weil das genutzte Verfahren ein Routing zwischen den einzelnen GPS-Punkten durchführt und bestehende Lücken im Netz so zu Umwegen führen können (der Algorithmus routet um die Lücke herum). Damit ergeben sich falsche Zuweisungen von Streckenabschnitten und dementsprechende Änderungen der Routeneigenschaften. Zur Minimierung dieses Fehlers wurden jedoch weitere Filterbedingungen am Ende des Verfahrens implementiert, die einen derartigen Fehler abfangen. Ungenau zugewiesene Routen wurden somit nicht berücksichtigt.

Eine relevante potentielle Fehlerquelle des Verfahrens besteht in seiner Anfälligkeit für Ausreißer. Die Berücksichtigung von Ausreißern (z.B. durch Punktspringen) kann zu anderen Routenverläufen und dementsprechend anderen Routeneigenschaften führen. Zur Vermeidung dieser Problematik wurden Ausreißer in vorhergehenden Schritten entfernt.

Ein Potential zur Verbesserung des genutzten Verfahrens bestünde in der Integration weiterer Parameter, wie bspw. der Genauigkeitswerte (accuracy) oder dem Zeitstempel der GPS-Punkte, anhand derer zusätzlich Wahrscheinlichkeiten für die Routenverläufe zwischen den Punkten bestimmt und genutzt werden könnten. Insgesamt wurde durch die Anpassungen des Map Matchings jedoch eine sehr robuste und nicht fehleranfällige Methode der Netzzuweisung genutzt.

Für die Erzeugung von Routenalternativen existieren zahlreiche Verfahren, die immer an die Anforderungen der jeweiligen Arbeit angepasst werden sollten. Für die vorliegende Arbeit wurde ein verhältnismäßig einfaches, jedoch sehr effektives geometrisches Verfahren genutzt, dass die gestellten Prämissen ausreichend gut bedient.

Die erzeugten Routenalternativen wiesen sehr große räumliche Unterschiede und nur minimale Überlappungen zu den gewählten Routen auf. Im Durchschnitt verfügten Routen und Alternativen nur zu rund 2 % (Mittelwert) bzw. 7 % (Median) über gemeinsame Routenabschnitte. Der Wert ist sehr gering angesichts der Anforderungen in der Literatur, nach der Alternativen sich zu mindestens 50 % voneinander unterscheiden sollten (siehe Kapitel 2.2.4). In der Arbeit wurden mit durchschnittlich erreichten Unterschieden von 98 % bis 93 % folglich sehr gute Ergebnisse bzgl. dieses Kriteriums erzielt.

Es muss jedoch festgehalten werden, dass bei den meisten Verfahren die Art der Erzeugung einen Einfluss auf die Analyseergebnisse ausüben kann. Dies ist auch bei dem genutzten Verfahren nicht auszuschließen. So kann bspw. der Einflussfaktor „Distanz“ an Bedeutung gewinnen, wenn sehr viele Routenalternativen (in anderen Studien z.B. bis zu 20 Stück) erzeugt werden, die zwangsläufig größere Umwege berücksichtigen. Die Reduktion auf wenige Alternativen (eine Route und ein bis zwei Alternativen) wird in diesem Zusammenhang als realistisch angesehen.

Damit die erzeugten Alternativen nicht nur durch das Nebennetz verlaufen, wurde nicht der kürzeste Weg bei der Suche nach Alternativen gesucht, sondern der Weg mit der geringsten Reisezeit. Die Nutzung der Reisezeit sollte sicherstellen, dass Alternativen nicht stets den kürzesten Weg darstellen und durch das Nebennetz verlaufen, sondern auch Alternativen durch das Hauptverkehrsnetz verlaufen, für die mehr Attribute im Angebotsnetz vorlagen. Die Analyse hat jedoch aufgezeigt, dass dies nur teilweise funktioniert hat.

Daher sollten unterschiedliche Möglichkeiten zur Verbesserung des Verfahrens in Betracht gezogen werden. So könnten bspw. weitere Attribute in die Erzeugung der Alternativen einbezogen werden. Die Suche von Alternativen könnte somit nicht nur auf der Reisezeit basieren, sondern bspw. auch die Radverkehrsführungsform und noch weitere Faktoren einbeziehen. Dazu wären jedoch einerseits sehr detaillierte und vollumfängliche Daten zum Angebotsnetz notwendig. Anderseits müsste untersucht werden, inwiefern sich die Nutzung solcher Verfahren auf die Analyseergebnisse auswirkt, weil eine Suche von Alternativen, die bereits bestimmte Einflussfaktoren berücksichtigt, zu veränderten Analyseergebnissen führen könnte.

Das genutzte logistische Regressionsverfahren stellt eine etablierte Methode zur Untersuchung diskreter Wahlentscheidungen dar. In Anbetracht der Vielzahl möglicher Modelle und Verfahren ist die Nutzung weiterer Verfahren für die Analyse jedoch durchaus

denkbar. Das verwendete Verfahren (Conditional Logit) wurde genutzt, weil mit diesem Modell die Unterschiede der Eigenschaften der Routen/Alternativen besonders gut in der Analyse berücksichtigt werden können.

Nichtsdestotrotz ist die Anwendung von anderen Regressionsmodellen, wie bspw. dem Multinomial Logit (MNL) oder Path Size Logit (PSL) denkbar, da diese Modelle ebenfalls etablierte Verfahren darstellen und für die Analyse der Routenwahl genutzt werden. Für die Analyse mittels MNL müsste jedoch auf andere Analyse-Software zurückgegriffen werde. BIOGEME, eine häufig genutzte Software zur Analyse von Entscheidungen im Verkehrsbereich, verlangt von Anwender*innen jedoch Kenntnisse in Python-Programmierung. Die Nutzung des in anderen Studien häufig verwendeten PSL war im vorliegenden Fall nicht notwendig, weil das PSL vor allem dann genutzt wird, wenn Routen und Alternativen viele gemeinsame Streckenabschnitte besitzen.

Anderen Methoden, wie bspw. Verfahren des „Maschinellen Lernens“, die in der jüngeren Vergangenheit vermehrt Einzug in die Verkehrswissenschaften gehalten haben, könnten ebenfalls für die Analyse der Routenwahl genutzt werden. In der Literatur existieren bereits einige Ansätze dazu – häufig mangelt es jedoch an Transparenz und Vergleichbarkeit.

Die Nutzung anderer Regressionsmodelle, erweiterter Modellformen und anderer Software würde es zudem ermöglichen, weitere Faktoren in die Analysen zu integrieren. So könnten bspw. geschlechter- oder altersspezifische Merkmale in die Analyse einfließen. Mit dem für die vorliegende Arbeit genutzten Verfahren müssten dazu jeweils einzelne Analysemodelle geschätzt werden, wovon aufgrund des Aufwands und Umfangs der Arbeit abgesehen wurde.

Die in den obigen Abschnitten benannten Stärken, Schwächen, Chancen und Risiken sind noch einmal stichpunktartig in Tabelle *22* zusammengefasst.

| Stärken des Verfahrens | Schwächen des Verfahrens |
|---|---|
| • Einzigartiger, großer Datensatz<br>• Sehr große Stichprobe mit vielen Fahrten von zahlreichen Radfahrer*innen sowie einer stadtweiten Netzabdeckung<br>• Proband*innen sind „Alltagsradler*innen“<br>• Zahlreiche Sekundärdaten<br>• Nutzung eines etablierten Analyseverfahrens<br>• Hohe Modell-Güte | • Stichprobe leicht männlich dominiert im Vergleich zu den Radfahrenden in der SrV-Stichprobe<br>• Altersverteilung der Proband*innen weicht leicht von der Verteilung in SrV ab<br>• Nutzung von einer Routenalternative für die Analyse<br>• Keine Berücksichtigung personenspezifischer Attribute |
| **Chancen für den Einsatz des Verfahrens** | **Risiken für den Einsatz des Verfahrens** |
| • Bessere Verkehrsplanung durch Nutzung des Routenwahlmodells in der Verkehrsmodellierung<br>• Effizientere Planung und Bewertung von Maßnahmen<br>• Höhere Effektivität der eingesetzten Mittel | • Restunsicherheit kann trotz Modell-Güte zu verzerrten Ergebnissen führen, die zu Fehlplanungen führen<br>• Das Modell berücksichtigt nicht die Entscheidungen aller Radfahrer*innen im Untersuchungsraum |

Tabelle 22: Zusammenfassung der Stärken, Schwächen, Chancen und Risiken des Verfahrens

## 6.3 Zusammenfassung

Die Interpretation der Ergebnisse sowie deren Gegenüberstellung mit anderer Forschungsarbeiten lässt den Schluss zu, dass die Ergebnisse der Arbeit plausibel sind. Die Wirkung der meisten aufgenommenen Einflussfaktoren zeigte sich in ähnlichem Maße in anderen Forschungsarbeiten (siehe Kapitel 3 und Kapitel 6.1). Dies trifft vor allem auf die Einflussfaktoren Distanz, Längsneigung, Radverkehrsführungsform, maximal zulässige Geschwindigkeit des MV, Flächennutzung und LSA geregelte Knotenpunkte zu.

Der Einfluss der Breite der Radverkehrsführung, der Radverkehrsstärken und der Oberflächenbeschaffenheit sowie der objektiven Sicherheit wurde zwar nur von einzelnen Studien untersucht. Die Ergebnisse der Studien decken sich jedoch größtenteils mit den Ergebnissen der vorliegenden Arbeit (siehe Kapitel 6.1).

Inwiefern die Anzahl der Fahrtstreifen des MV und des ruhenden Verkehrs die Routenwahl von Radfahrenden beeinflussen, wurde von den in Kapitel 3 vorgestellten Studien nicht untersucht. Daher erweitern die Ergebnisse der vorliegenden Arbeit auch den internationalen Wissensstand.

Der Einfluss der Kraftfahrzeugstärken, der subjektiven Sicherheit sowie der Knotenpunkte mit LSA-Regelung lässt sich hingegen kontrovers diskutieren. Während sich in einigen Studien ein positiver Einfluss auf die Routenwahl ergab, konnte in anderen Studien ein negativer Einfluss nachgewiesen werden (siehe Kapitel 6.1).

Etwaige Unterschiede zwischen den Ergebnissen der vorliegenden Arbeit und anderen Forschungsarbeiten werden vor allem auf die unterschiedlichen Daten sowie Methoden zurückgeführt. Eine Stärke der vorliegenden Arbeit stellen vor allem die genutzten Primärdaten dar, die durch die Vielzahl an Nutzer*innen und Fahrten einen wertvollen Beitrag zur Untersuchung darstellen – auch wenn Alters- und Geschlechterverteilung der Proband*innen leicht von den Verteilungen von Haushaltsbefragungen (SrV) abweichen. Wesentliche Chancen zur Verbesserung der Ergebnisse bestehen vor allem in der Erweiterung bzw. Vervollständigung der Sekundärdaten (Verkehrsangebotsnetz) sowie der Nutzung anderer Analysemodelle, die eine Integration zusätzlicher Variablen erlauben.

# 7. Fazit und Ausblick

Ausgangspunkt der vorliegenden Arbeit war, dass bisher nur unzureichende Informationen zu den Einflussfaktoren der Routenwahl im Radverkehr vorlagen, die auf der Analyse von Daten zum real beobachteten Routenwahlverhalten basieren. Das Fehlen dieser Informationen lässt einerseits keine fundierten Aussagen zu den von Radfahrenden präferierten Routeneigenschaften zu. Darüber hinaus fehlen Modelle für die konkrete Abschätzung von Maßnahmenwirkungen im Radverkehr (z.B. im Rahmen einer Verkehrsnachfragemodellierung).

Bei den bereits existierenden Studien, die die Routenwahl auf Basis von Daten zum real beobachteten Routenwahlverhalten analysierten, handelt es sich vor allem um internationale Arbeiten, sodass kein Bezug zu deutschen Städten hergestellt werden kann. Die Studienergebnisse lassen sich dadurch nur bedingt auf den deutschen Raum übertragen.

Um die Frage nach den signifikanten Einflussfaktoren der Routenwahl in deutschen Städten zu beantworten, wurde daher die Routenwahl am Fallbeispiel der Stadt Dresden untersucht. Dazu wurde ein umfangreicher Primärdatensatz während der Aktion STADTRADELN erhoben und aufbereitet. Die aufbereiteten Routendaten wurden mit den Eigenschaften der genutzten Strecken, die in einem Verkehrsangebotsnetz hinterlegt wurden, verknüpft. Dadurch konnten die Eigenschaften der von den Radfahrenden in Dresden gewählten Routen bestimmt werden. Zur Analyse und Quantifizierung der unterschiedlichen Einflussfaktoren wurde die Routenwahl mit einem logistischen Regressionsverfahren analysiert und ausgewertet.

Die Analyse ergab, dass die verschiedenen in die Untersuchung einbezogenen Einflussfaktoren die Routenwahl meist signifikant, aber in unterschiedlich starkem Maße beeinflussen. So wirken sich eine zunehmende Distanz und Längsneigung, eine geringe Breite der Radverkehrsführung und eine höhere Unfallhäufigkeit entlang einer Route negativ auf die Auswahlwahrscheinlichkeit einer Route aus. Eine geringe Längsneigungen, die Existenz von Radverkehrsinfrastruktur, das Vorhandensein anderer Radfahrender entlang einer Route sowie eine geringere zulässige Maximalgeschwindigkeit des MV und die Existenz von nur einem Fahrstreifen für den motorisierten Verkehr wirken sich hingegen ebenso positiv auf die Wahl einer Route aus, wie hohe Anteile von Asphaltoberflächen, Grün- und Wohngebietsflächen, Punkte kritischer Situationen und eine zunehmende Anzahl LSA geregelter Knotenpunkte entlang der Route. Es konnten keine (signifikanten) Einflüsse der durchschnittlich täglichen Verkehrsstärke des Kfz-Verkehrs, des Oberflächentyps „Kopfsteinpflaster“, des längs angeordneten ruhenden Verkehrs sowie

der Häufigkeit von „rechts-vor-links“ geregelten Knotenpunkten entlang der Route gefunden werden. Die Ergebnisse sind unterschiedlich zu interpretieren und teils beeinflusst durch die Sekundärdatenverfügbarkeit.

Der Beitrag der vorliegenden Arbeit besteht vor allem in der Quantifizierung der Wirkung der unterschiedlichen Einflussfaktoren der Routenwahl. Eine Untersuchung der Routenwahl deutscher Radfahrender wurde bis zur Anmeldung der vorliegenden Arbeit in diesem Maße nicht auf Basis von GPS-basierten Daten zum real beobachteten Routenwahlverhalten durchgeführt. Die Ergebnisse der Arbeit geben jedoch nicht nur Einblick in die Routenwahl des Radverkehrs und seine Einflussfaktoren. Das resultierende Routenwahlmodell kann darüber hinaus für die Abschätzung von Maßnahmenwirkungen genutzt werden. Als Mehrwert der Arbeit kann auf internationaler Ebene angeführt werden, dass die Wirkung von Einflussfaktoren analysiert wurde, die in bisherigen Studien noch keine Berücksichtigung fand (z.B. Fahrstreifenanzahl des MV oder ruhender Verkehr).

Die kritische Reflexion und Diskussion der Ergebnisse und Methoden zeigt, dass die Analyse und deren Ergebnisse durch die Nutzung weiterer Daten und Methoden verbessert werden könnte. Die Nutzung anderer bzw. weiterer Primärdaten, die bspw. Nutzer*innengruppen jenseits der Aktion STADTRADELN beinhalten, könnte vermutlich helfen, die Routenwahl des „durchschnittlichen Radfahrenden“ noch genauer abzubilden. Gleiches gilt für die Nutzung der Sekundärdaten, deren größere räumliche Abdeckung (z.B. durch eine Vollerhebung im Stadtgebiet) zu einer höheren Verlässlichkeit der Analyseergebnisse beitragen könnte. Nicht zuletzt würde die Nutzung anderer logistischer Regressionsmodelle oder die Nutzung gänzlich anderer Verfahren (z.B. maschinelle Lernverfahren) möglicherweise dazu beitragen, die Routenwahl noch akkurater abzubilden.

Die Untersuchung konnte zunächst Einblicke in die Routenwahl von Radfahrenden in einer deutschen Stadt geben. Es bleibt offen, ob die Routenwahl der Radfahrenden in Dresden repräsentativ für die Routenwahl in anderen deutschen Städten ist. Daher sollten weitere Arbeiten mit vergleichenden Analysen angestrebt werden, um bspw. ähnliche Tendenzen im Routenwahlverhalten in anderen Städten zu untersuchen. Die Untersuchungen sollten dabei für verschiedene deutsche Städte angestrebt werden, um möglichst auch stadtspezifische Unterschiede (z.B. in Topographie, Stadtgröße oder politischer Unterstützung des Radverkehrs) in der Analyse zu berücksichtigen. Dies könnte einerseits helfen, existierende Unterschiede bei der Routenwahl deutscher Radfahrender festzustellen. Andererseits könnten deutschlandweite Gemeinsamkeiten – also fundamentale Einflussfaktoren und deren Wirkung – herausgestellt werden.

# Eidesstattliche Erklärung

Hiermit erkläre ich, dass ich die vorliegende Arbeit selbständig und ohne Benutzung anderer als der angegebenen Hilfsmittel angefertigt habe. Die aus fremden Quellen wörtlich oder sinngemäß übernommenen Gedanken sind als solche kenntlich gemacht.

Dresden, ..... .....

Unterschrift des Promovenden

# Literaturverzeichnis

Aberle, Christoph, und Florian Pühringer. „BIke Intelligence: Analyse von Radverkehrsdaten als Werkzeug für den ÖPNV.“ *Mobilogisch*, 2017: 141-160.

Ahrens, Gerd-Axel. „Die Stunde der Wahrheit - Präsentation und Diskussion der Ergebnisse des SrV 2013.“ Herausgeber: Technische Universität Dresden. 2014. https://tu-dresden.de/bu/verkehr/ivs/srv/ressourcen/dateien/2013/Schlusskonferenz/SrV2013-Abschluss_Ahrens_2014-11-10.pdf?lang=de.

Alpaydin, Ethem. *Introduction to Machine Learning, Third Edition.* Cambridge: MIT Press. Adaptive Computation and Machine Learning series, 2014.

Alrutz, Dankmar , et al. *Einfluss von Radverkehrsaufkommen und Radverkehrsinfrastruktur auf das Unfallgeschehen.* Forschungsbericht Nr. 29, Berlin: Unfallforschung der Versicherer. Gesamtverband der Deutschen Versicherungswirtschaft e. V. (GDV)., 2015.

Aoun, Alisar, Julie Bjornstad, Brooke DuBose, Meghan Mitman, und Mollie Pelon. *Bicycle and Pedestrian Forecasting Tools: State of the Practice.* Chape Hill, North Carolina: White Paper Series of the Federal Highway Administration, 2015.

Arndt, Marc. „Maschinelles Lernen in derAnschlussdisposition.“ 2016. https://www.ke.tu-darmstadt.de/lehre/arbeiten/bachelor/2016/Arndt_Marc.pdf (Zugriff am 10. Dezember 2020).

Aultman-Hall, Lisa, Fred L. Hall, und Brian B. Baetz. „Analysis of Bicycle Commuter Routes Using Geographic Information Systems - Implications for Bicycle Planning.“ *TRANSPORTATION RESEARCH RECORD Vol. 1578 Issue 1*, 1997: 102-110.

Axhausen, Kay W., Stefan Schönfelder, Jean Wolf, M. Oliveira, und U. Samaga. „Eighty Weeks of Global Positioning System Traces: Approaches to Enriching Trip Information.“ *Transportation Research Record Journal of the Transportation Research Board*, 2004.

Backhaus, Klaus, Bernd Erichson, Wulff Plinke, und Rolf Weiber. *Multivariate Analysemethoden - Eine anwendungsorientierte Einführung.* Berlin, Heidelberg: Springer Gabler, 2016.

Bader, Roland, Jonathan Dees, Robert Geisberger, und Peter Sanders. „Alternative Route Graphs in Road Networks.“ *International Conference on Theory and Practice of Algorithms in (Computer) Systems*, 2011: 21-32.

Becker, Udo, und Tibor Petzoldt. *RadVerS – Mit Smartphones generierte Verhaltensdaten im Verkehr – Differenzierung des Nutzerverhaltens unterschiedlicher RadfahrerInnengruppen.* Projektabschlussbericht, Dresden: Technische Universität Dresden, 2019.

Ben-Akiva, M., und S. Lerman. „Discrete choice analysis: theory and applications to travel demand.“ *MIT Press Series in Transportation Studies*, 1985: 59-99.

Berhends, Ehrhard. „Maschnielles lernene - Eine Einführung.“ 2016. http://page.mi.fu-berlin.de/bhrnds/skripten/maschinelleslernen2016.pdf (Zugriff am 20. Oktober 2020).

Bhavsar, Parth, Ilya Safro, Nidhal Bouaynaya, Robi Polikar, und Dimah Dera. „Chapter 12 - Machine Learning in Transportation Data Analytics.“ *Data Analytics for Intelligent Transportation Systems*, 2017: 283-307.

Bierlaire, Michel, Jingmin Chen, und Jeffrey Newman. „A probabilistic map matching method for smartphone GPS data." *Transportation Research Part C: Emerging Technologies*, 2013: 78-98.

Biljecki, Filip, Hugo Ledoux, und Peter van Oosterom. „Transportation mode-based segmentation and classification of movement trajectories." *International Journal of Geographical Information Science, 27(2)*, 2013: 385-407.

Bin, Yu, Yang Zhongzhen, und Yao Baozhen. „Bus Arrival Time Prediction Using Support Vector Machines." *Journal of Intelligent Transportation Systems - Technology, Planning, and Operations.*, 2006: 151-158.

BMVI, Bundesministerium für Verkehr und Digitale Infrastruktur. „Radverkehr in Deutschland - Zahlen, Daten, Fakten." Herausgeber: Deutsches Institut für Urbanistik gGmbH (Difu). 2014. https://www.ziv-zweirad.de/fileadmin/redakteure/Downloads/PDFs/radverkehr-in-zahlen.pdf (Zugriff am 5.. Sept. 2018).

BMVIT. „Bundesministerium für Verkehr, Innovation und Technologie. Kosteneffiziente Maßnahmen zur Förderung des Radverkehrs in Gemeinden." 2013. https://www.fahrradland-bw.de/fileadmin/user_upload/Kosteneffiziente_Massnahmen_zur_RVFoerderung.pdf (Zugriff am 6. Oktober 2020).

Bohrmann, Nathalie, und Jörg Thiemann-Linden. „Forschung Radverkehr - Fahrradnutzung im Städtevergleich." Herausgeber: Duetsche Institut für Urbanistik (Difu) gGmbH. 2012. https://nationaler-radverkehrsplan.de/sites/default/files/forschung_radverkehr/for_a-07.pdf (Zugriff am 5. Oktober 2020).

Bohte, Wendy, und Kees Maat. „Deriving and validating trip purposes and travel modes for multi-day GPS-based travel surveys: A large-scale application in the Netherlands." *Transportation Research Part C: Emerging Technologies*, 2009: 285-297.

Brenck, Andreas, Kay Mituschi, und Martin Winter. „Die externen Kosten des Verkehrs." In *Handbuch Verkehrspolitik*, von Oliver Schöller, Canzler Weert und Andreas Knie, 425-452. VS Verlag für Sozialwissenschaften, 2007.

Broach, Joseph, Jennifer Dill, und John Gliebe. „Where do cyclists ride? A route choice model developed with revealed preference GPS data." *Transportation Research Part A*, 2012: 1730-1740.

Broach, Joseph, John Gliebe, und Jennifer Dill. „Development of a Multi-class Bicyclist Route Choice Model Using Revealed Preference Data." *Proceedings of the 12th International Conference on Travel Behavior Research, Jaipur, India.*, 2009: 1-31.

Call a Bike. *Call a BIke in deiner Stadt.* 2020. https://www.callabike.de/de/staedte (Zugriff am 14. Oktober 2020).

Cascetta, Ennio. *Transportation Systems Engineering: Theory and Methods.* Dordrecht: Springer Science+Business Media, 2001.

Casello, Jeffrey M. , und Vladimir Usyukov. „Modeling Cyclists' Route Choice Based on GPS Data." *Transportation Research Record: Journal of the Transportation Research Board*, 2014.

Chen, Peng, Qing Shen, und Suzanne Childress. „A GPS data-based analysis of built environment influences on bicyclist route preferences." *International Journal of Sustainable Transportation*, 2017: 218-231.

Chen, Yanyan, Michael G. H. Bell, und Klaus Bogenberger. „Reliable Pretrip Multipath Planning and Dynamic Adaptation for a Centralized Road Navigation System." *EEE Transactions on Intelligent Transportation Systems, vol. 8, no. 1*, 2007: 14-20.

Chicco, Davide. „Ten quick tips for machine learning incomputational biology." *BioData Mining*, 2017: 1-17.

Cohen, Jacob. *Statistical Power Analysis fo the Behavioral Science.* New York: Lwarence Erlbaum Associates, 1988.

Connect, DB. *Call A Bike. Reportingdaten zu Call-a-Bike, inkl. CaB-Daten von Konrad Kassel und Stadtrad Hamburg, exkl. Daten weiterer Partner.* 2020. https://data.deutschebahn.com/dataset/data-call-a-bike (Zugriff am 14. Oktober 2020).

Cooper, H. M. „Integrating research: a guide for literature reviews." *pplied Social Research Methods Series, vol. 2. SAGE Publications*, 1989.

Cronin, Patricia, Frances Ryan, und Michael Coughlan. „Undertaking a literature review: a step-by-step approach." *British Journal of Nursing*, 2008: Vol 17, No 1.

DESTATIS. *Haushalte und Haushaltsmitglieder für Deutschland, das frühere Bundesgebiet und die Neuen Länder einschließlich Berlin.* Herausgeber: Statistisches Bundesamt. 2020. https://www.destatis.de/DE/Themen/Gesellschaft-Umwelt/Bevoelkerung/Haushalte-Familien/Tabellen/1-1-privathaushalte-haushaltsmitglieder.html (Zugriff am 05. Oktober 2020).

—. *Pressemitteilung Nr. 223 vom 19. Juni 2020: Bevölkerung in Deutschland im Jahr 2019 auf 83,2 Millionen gestiegen.* 2020. https://www.destatis.de/DE/Presse/Pressemitteilungen/2020/06/PD20_223_12411.html (Zugriff am 5. Oktober 2020).

—. „Unfallentwicklung auf deutschen Straßen 2017." Herausgeber: Statistisches Bundesamt. 2019. https://www.destatis.de/DE/Presse/Pressekonferenzen/2018/Verkehrsunfaelle-2017/pressebroschuere-unfallentwicklung.pdf?__blob=publicationFile&v=3 (Zugriff am 5. Oktober 2020).

—. „Verkehrsunfälle - Getötete bei Verkehrsunfällen nach Art der Verkehrsbeteiligung." Herausgeber: Statistisches Bundesamt. 2020. https://www.destatis.de/DE/Themen/Gesellschaft-Umwelt/Verkehrsunfaelle/Tabellen/getoetete-fahrzeugart.html (Zugriff am 5. Oktober 2020).

Dia, Hussein, und Sakda Panwai. „Comparative Evaluation of Models of Route Choice and Driver Compliance with Traffic Information." *29th Australasian Transport Research Forum*, 2006: 1-12.

Döbel, Inga, et al. *MASCHINELLES LERNEN - Eine Analyse zu Kompetenzen, Forschung und Anwendung.* Forschungsbericht, München: Fraunhofer-Gesellschaft, 2018.

El-Rabbany, Ahmed. *Introduction to GPS. The global positioning system. .* Norwodd: ARTECH HOUSE, 2002.

Ertel, Wolfgang. *Grundkurs Künstliche Intelligenz: Eine praxisorientierte Einführung (Computational Intelligence).* Wiesbaden: Springer Vieweg, 2016.

FGSV. *Empfehlungen für Radverkehrsanlagen - ERA.* Köln: Forschungsgesellschaft für Straßen- und Verkehrswesen e.V., 2010.

—. *Empfehlungen fürAnlagen des ruhenden Verkehrs - EAR 05.* Köln: FORSCHUNGSGESELLSCHAFT FÜR STRASSEN- UND VERKEHRSWESEN., 2005.

—. *EVE - Empfehlungen für Verkehrserhebungen.* Bde. 978-3-941790-99-5. Köln: Forschungsgesellschaft für Straßen- und Verkehrswesen e.V., 2012.

—. *EVP - Empfehlungen für Verkehrsplanungsprozesse EVP.* Köln: Forschungsgesellschaft für Straßen- und Verkehrswesen e.V., 2018.

—. *Richtlinien für die Anlage von Stadtstraßen - RASt.* Köln: Forschungsgesellschaft für Straßen- und Verkehrswesen e.V., 2006.

—. *Richtlinien für Lichtsignalanlagen - Lichtzeichenanlagen für den Straßenverkehr.* Bde. 978-3-939715-91-7. Köln: Forschungsgesellschaft für Straßen- und Verkehrswesen, 2015.

Fliegauf, Harald. „Verkehrsberuhigung und ruhender Verkehr in Innenstädten." *Zeitschrift für Rechtspolitik. 27. Jahrg., H. 10*, 1994: 386-388.

Friedrich, Felix. *Alternativrouten im Radverkehr. Studienarbeit.* Dresden: Technische Universität Dresden, 2019.

Friedrich, T, J Broach, J Gliebe, und J Dill. „Entwicklung eines Routenwahl-Verfahrens fuer den Radverkehr mit Hilfe von Revealed-Preference-Daten." *Straßenverkehrstechnik*, 2011.

Frochte, Jörg. *Maschinelles Lernen - Grundlagen und Algorithmen in Python.* München: Carl Hanser Verlag, 2018.

Geofabrik. *OpenStreetMap Data Extracts.* 2018. https://download.geofabrik.de/ (Zugriff am 13. September 2018).

GeoSN. *Wappen vom Freistaat Sachsen Vermessung Sachsen GeoSN.* 2020. https://www.landesvermessung.sachsen.de/verfugbarkeit-aktualitat-5305.html (Zugriff am 13. November 2020).

Ghanayim, Muhammad , und Shlomo Bekhor. „Modelling bicycle route choice using data from a GPS-assisted household survey." *European Journal of Transport and Infrastructure Research (EJTIR)* , 2018: 158-177.

GitHub. *Graphhopper Routing Bike Common Flag Encoder.* 2020. https://github.com/graphhopper/graphhopper/blob/0.12/core/src/main/java/com/graphhopper/routing/util/BikeCommonFlagEncoder.java#L128-L190 (Zugriff am 13. November 2020).

Gong, Hongmian, Cynthia Chen, Evan Bialostozky, und Catherine T. Lawson. „A GPS/GIS method for travel mode detection in New York City." *Computers, Environment and Urban Systems*, 2012: 131-139.

Gonga, Lei, Takayuki Morikawab, Toshiyuki Yamamot, und Sato Hitomi. „Deriving Personal Trip Data from GPS Data: A Literature Review on the Existing Methodologies.“ *Procedia - Social and Behavioral Sciences 138. The 9th International Conference on Traffic & Transportation Studies (ICTTS'2014)*, 2014: 557-565.

Graphhopper. *Open Source Routing Software from GraphHopper.* 2020. https://github.com/graphhopper (Zugriff am 13. November 2020).

Graphhopper-b. *Map Matching based on GraphHopper.* 2020. https://github.com/graphhopper/map-matching (Zugriff am 25. November 2020).

Hagemeister, Carmen. „Objektive Sicherheit versus subjektives Sicherheitsgefühl.“ *3. Nationaler Radverkehrskongress. Den Radverkehr gemeinsam weiterentwickeln.* 2013. https://tu-dresden.de/mn/psychologie/iaosp/diagnostische/ressourcen/dateien/mitarbeiter/publikationen2/publikationen_carmen_hagemeister/nat_rvk_2013_hagemeister_ohne_fremde_bilder.pdf?lang=de (Zugriff am 16. November 2020).

Hofmann-Wellenhof, B., H. Lichtenegger, und J. Colli. *GPS Theory and Practice.* Springer Verlag, 2001.

Hood, Jeffrey, Elizabeth Sall, und Billy Charlton. „A GPS-based bicycle route choice model for San Francisco, California.“ *Transportation Letters: The International Journal of Transportation Research*, 2011: 63-75.

Horvat, Tomislav, und Josip Job. „The use of machine learning in sport outcome prediction: A review.“ *WIREs Data Mining Knowlledge Discovery*, 2020.

IBM-a. *IBM Support - Can IBM SPSS Statistics fit discrete choice models?* Herausgeber: IBM. 16.. April 2020. https://www.ibm.com/support/pages/can-ibm-spss-statistics-fit-discrete-choice-models (Zugriff am 2020).

IBM-b. *IBM Support - Conditional logistic regression using COXREG.* Herausgeber: IBM. 16. April 2020. https://www.ibm.com/support/pages/conditional-logistic-regression-using-coxreg (Zugriff am 2020).

Jestico, Ben, Trisalyn Nelson, und Meghan Winters. „Mapping ridership using crowdsourced cycling data.“ *Journal of Transport Geography*, 2016.

Kang, Lei, und Jon D. Fricker. „Bicyclist commuters' choice of on-street versus off-street route segments.“ *Transportation*, 2013: 887-902.

Khatri, Ranjit, Christopher R. Cherry, Shashi S. Nambisan, und Lee D. Han. „Modeling Route Choice of Utilitarian Bikeshare Users with GPS Data.“ *Transportation Research Record: Journal of the Transportation Research Board*, 2016: 141–149.

Klima-Bündnis. *Über das Klima-Bündnis.* 2020. https://www.klimabuendnis.org/ueber-uns.html (Zugriff am 29. Oktober 2020).

Knödel, Walter. *Graphentheoretische Methoden und ihre Anwendungen.* Berlin, Heidelberg: Springer-Verlag, 2012.

Koh, P.P., und Y.D. Wong. „Influence of infrastructural compatibility factors on walking and cycling route choices.“ *Journal of Environmental Psychology*, 2013: 202-213.

Kohla, Birgit. „Automatische Verkehrsmittelerkennung aus Sensordaten.“ *Agit 2014 - Symposium Angewandte Geoinformatik - Salzburg, Austria*, 2014: 489-494.

Köhler, Uwe. *Einführung in die Verkehrsplanung: Grundlagen, Modellbildung, Verkehrsprognose, Verkehrsnetze.* Herausgeber: Fraunhofer IRB Verlag. 2014.

Krause, Juliane, und Edzard Hildebrandt. „Modellvorhaben „Fußgänger- und fahrradfreundliche Stadt“ - Chancen des Fuß- und Radverkehrs als Beitrag zur Umweltentlastung.“ Herausgeber: Umweltbundesamt. 2006. https://www.umweltbundesamt.de/sites/default/files/medien/publikation/long/2989.pdf (Zugriff am 6. Oktober 2020).

Krizek, Kevin J. , Ahmed M. El-Geneidy, und Kristin Thompson. „A Detailed Analysis of How an Urban Trail System Affects Cyclists' Travel.“ *Transportation: Planning, Policy, Research, Practice*, 2007: Volume 34, Issue 5, pp 611-624.

Lai, Xinjun, Hui Fu, Jun Li, und Zhiren Sha. „Understanding Drivers’ Route Choice Behaviours in the Urban Network with Machine Learning Models.“ *IET Intelligent Transport Systems*, 2018.

Larsen, Jacob, und Ahmed El-Geneidy. „A travel behavior analysis of urban cycling facilities in Montréal, Canada.“ *Transportation Research Part D: Transport and Environment. Volume 16, Issue 2*, 2011: Pages 172-177.

Lazarescu, Anna. *Roadmap Magazine.* 2020. https://roadmap-magazine.de/radwende-in-wiesbaden-so-soll-nicht-nur-diese-stadt-fahrradfreundlich-gemacht-werden/ (Zugriff am 14. Oktober 2020).

Lee, By SooBeom, YoungChan Kim, Namgung Moon, und Jangwook Kim. „Development of Route Choice Behavior Model using Linkage of Neural Network and Genetic Algorithm with Trip Information.“ *KSCE Journal of Civil Engineering*, 2005: 321-327. Vol. 9, No. 4.

Lemke, Kerstin. „Forschungsgesellschaft für Straßen- und Verkehrswesen e.V.“ *Ermittlung der Verkehrsnachfrage.* 2015. https://www.fgsv-verlag.de/pub/media/pdf/299_Lemke.pdf (Zugriff am 16. November 2020).

LH-Dresden-a. „Landeshauptstadt Dresden - Umweltamt. Klimatische Situation in Dresden.“ 2019. https://www.dresden.de/media/pdf/umwelt/Klimatische_Situation_Dresden.pdf (Zugriff am 28. Oktober 2020).

LH-Dresden-b. „Landehausptstadt Dresden, Kommunale Statistikstelle. Flächennutzung nach Stadtteilen Januar 2020.“ 2020. https://www.dresden.de/media/pdf/statistik/Statistik_1110_Flaechennutzung_Stadtteile.pdf (Zugriff am 28. Oktober 2020).

LH-Dresden-c. *Landeshauptstadt Dresden. Leben in Dresden - Bevölkerungsbestand.* 2020. https://www.dresden.de/de/leben/stadtportrait/statistik/bevoelkerung-gebiet/Bevoelkerungsbestand.php (Zugriff am 28. Oktober 2020).

LH-Dresden-d. „Landeshauptstadt Dresden. Geschäftsbereich Stadtentwicklung, Bau, Verkehr und Liegenschaften. Ergebnisse der repräsentativen Haushaltbefragung „SrV 2018“ zur privaten Mobilität in Dresden.“ 2020. https://www.dresden.de/media/pdf/stadtplanung/verkehr/SrV_2018_Ergebnisse.pdf (Zugriff am 28. Oktober 2020).

LH-Dresden-e. *Landeshauptstadt Dresden. Themenstadtplan - Verkehr, Radverkehr - Dauerzählstellen.* 2019. http://stadtplan2.dresden.de/(S(szcgblc3qlw0aj3izpwoyijn))/spdd.aspx?TH=STA_FAHRRADZAEHLST (Zugriff am 2019).

LH-Dresden-f. „Radverkehrskonzept der Landeshauptstadt Dresden.“ 2017. https://www.dresden.de/media/pdf/stadtplanung/verkehr/RadKonz_2017.pdf (Zugriff am 29. Oktober 2020).

LH-Dresden-g. „Landeshauptstadt Dresden. Verkehrsmengenkarte im städtischen Themenstadtplan.“ 2020. https://stadtplan.dresden.de/(S(w3wdjtsp3xerwgq5hjgrawpx))/spdd.aspx?TH=STA_VERKEHRSMENGEN&POS-LatLon=51.049156|13.744919&POS-OFFSET=1500&POS-MARK=0 (Zugriff am 24. November 2020).

LH-Dresden-h. *Landeshauptstadt Dresden. Flächennutzungsplan Stadt Dresden.* 2020. https://www.dresden.de/de/stadtraum/planen/stadtentwicklung/stadtplanung/flaechennutzungsplan-stadt-dresden.php (Zugriff am 24. November 2020).

LH-Dresden-i. *Das Klima von Dresden.* 2020. https://www.dresden.de/de/stadtraum/umwelt/umwelt/klima-und-energie/stadtklima/Klima_von_Dresden.php (Zugriff am 28. Oktober 2019).

LH-Dresden-j. „Landeshauptstadt Dresden - Verkehrsnetz und Verkehrsbelegung. Verkehrsnetze - Autobahnen, Straßen, Wege, Brücken und Tunnel.“ 19.. Mai 2020. https://www.dresden.de/media/pdf/statistik/Statistik_3501_Verkehrsnetze_2014.pdf (Zugriff am 2021).

Li, Tiger, und S. Tamer Cavusgil. „A classification and assessment of research streams in International Marketing.“ *International Business Review*, 1995: 251-277.

Lißner, Sven, Angela Francke, und Thilo Becker. „Big Data im Radverkehr. Ein anwendungsorientierter Leitfaden zur Nutzung von smartphone-generierten Radverkehrsdaten.“ 2017. file:///C:/Users/Huber/AppData/Local/Temp/Endbericht_Big_Data_im_Radverkehr.pdf (Zugriff am 28. Oktober 2020).

Lißner, Sven, Angela Francke, und Tilo Becker. „Modeling Cyclists Traffic Volume – Can Bicycle Planning Benefit from Smartphone Based Data?“ *Proceedings of 7th Transport Research Arena TRA 2018*, 2018.

Lißner, Sven, Maike von Harten, und Stefan Huber. *Mobilität von Radfahrenden in Deutschland – Nutzerbefragung im Rahmen der Kampagne Stadtradeln.* Verkehrsökologische Schriftenreihe Heft 15/2021, Dresden: Technische Universität Dresden, 2021.

Lißner, Sven, und Angela Francke. *Big Data im Radverkehr. Ein anwendungsorientierter Leitfaden zur Nutzung von smartphone-generierten Radverkehrsdaten.* Dresden: TU Dresden, Professur für Verkehrsökologie, Professur für Verkehrspsychologie, 2017.

Lohse, Dieter, und Werner Schnabel. *Grundlagen der Straßenverkehrstechnik und der Verkehrsplanung - Band 2 Verkehrsplanung.* KIRSCH BAUM, BEUTH, 2011.

Lott, Dale F., Timothy Tardiff, und Donna Y. Lott. „Evaluation by experienced riders of a new bicycle lane in an established bikeway system.“ *Transportation Research Record. Journal of the Transportation Research Board*, 1978: 40-46.

McFadden. „Conditionallogit analvsis of qualitative choice behavior.“ In *Frontiers in Econometrics*, von P. Zarernbka, 105–135. New York: Wiley, 1973.

McFadden, D. „The mathematical theory of demand models. In: P. Stopher, A. Meyburg (Eds.), Behavioural Travel Demand Models.“ 1976: 75-96.

Menghini, G., N. Carrasco, N. Schüssler, und K.W. Axhausen. „Route choice of cyclists in Zurich.“ *Transportation Research Part A*, 2010: 754-765.

MiD. *Mobilität in Deutschland - Ergebnisbericht.* Bundesministerium für Verkehr und digitale Infrastruktur (BMVI), 2018.

MiD. „Mobilität in Deutschland 2008 – Ergebnisbericht: Struktur - Aufkommen - Emissionen - Trends.“ 2008.

Morik, Katharina. „Schlüsseltechnologie Maschinelles Lernen.“ 2018. https://link.springer.com/article/10.1007/s42354-018-0120-4 (Zugriff am 20. Oktober 2020).

NASA. *Global Positioning System.* 2017. https://www.nasa.gov/directorates/heo/scan/communications/policy/GPS.html (Zugriff am 14. Oktober 2020).

—. *Global Positioning System History. National Aeronautics and Space Administration (NASA).* 2017. https://www.nasa.gov/directorates/heo/scan/communications/policy/GPS_History.html (Zugriff am 14. Oktober 2020).

—. „GLOBAL POSITIONING SYSTEM STANDARD POSITIONING SERVICE PERFORMANCE.“ 2008. https://www.gps.gov/technical/ps/2008-SPS-performance-standard.pdf (Zugriff am 14. Oktober 2020).

NASA-b. *Shuttle Radar Topography Mission - U.S. Releases Enhanced Shuttle Land Elevation Data.* 2020. https://www2.jpl.nasa.gov/srtm/ (Zugriff am 13. November 2020).

Newson, Paul, und John Krumm. „Hidden Markov map matching through noise and sparseness.“ *Proceedings of the 17th ACM SIGSPATIAL International Symposium on Advances in Geographic Information Systems, ACM-GIS 2009, November 4-6, 2009, Seattle, Washington, USA*, 2009: 336-343.

Nextbike. *Nextbike Original Bike Sharing.* 2020. https://www.nextbike.de/de/standorte/ (Zugriff am 14. Oktober 2020).

Nobis, Claudia. *Mobilität in Deutschland - MiD, Analysen zum Rad- und Fußverkehr.* Bonn, Berlin: Studie von infas, DLR, IVT und infas360 im Auftrag des Bundesministeriums für Verkehr und digitale Infrastruktur, 2019.

NRVP. *Nationaler Radverkehrsplan - Förderung des Radverkehr.* 2020. https://nationaler-radverkehrsplan.de/de/bund/foerderung-des-radverkehrs (Zugriff am 06. Oktober 2020).

—. *Nationaler Radverkehrsplan 2020 .* 2020. https://nationaler-radverkehrsplan.de/de/bund/nationaler-radverkehrsplan-nrvp-2020 (Zugriff am 6. Oktober 2020).

Piekenbrock, Dirk. *"Nachfrage". Gabler Wirtschaftslexikon.* 2020. https://wirtschaftslexikon.gabler.de/definition/nachfrage-39103/version-262521 (Zugriff am 12. Oktober 2020).

Pollert, Achim, Bernd Kirchner, und Javier Morato Polzin. *Duden Wirtschaft von A bis Z: Grundlagenwissen für Schule und Studium, Beruf und Alltag.* Mannheim: Bibliographisches Institut AG, 2016.

Powers, David M.W. „Evaluation: From Precision, Recall and F-Factor to ROC, Informedness, Markedness & Correlation." *Technical Report SIE-07-001. School of Informatics and Engineering. Flinders University • Adelaide • Australia*, 2007.

Qualtrics. *Qualtrics - Die richtige Stichprobengröße bestimmen.* 2021. https://www.qualtrics.com/de/erlebnismanagement/marktforschung/online-stichproben/ (Zugriff am 13,. April 2021).

Rodrigue, Jean-Paul. *The Geography of Transport Systems.* New York: Routledge, 2020.

Rodríguez, Germán . *Generalized Linear Models - 6.3 The Conditional Logit Model.* Herausgeber: Princeton University. 2020. https://data.princeton.edu/wws509/notes/c6s3 (Zugriff am 2021).

Roth, Benjamin, und Annemarie Friedrich. „Einführung in die Computerlinguistik - Maschinelles Lernen." Herausgeber: Ludwig-Maximilians-Universität München. 2016. https://sp1718.github.io/05_maschinelles_lernen_intro.pdf (Zugriff am 10.. Dezember 2020).

Rötzer, Florian. *Global Positioning System ist jetzt für die zivile Nutzung genauer.* 2000. https://www.heise.de/tp/features/Global-Positioning-System-ist-jetzt-fuer-die-zivile-Nutzung-genauer-3447120.html (Zugriff am 14. Oktober 2020).

Sabel, David. „Einf¨uhrung in die Methoden der Künstlichen Intelligenz." Herausgeber: Goethe Universität Frankfurt am Main. 2012. https://www.ki.informatik.uni-frankfurt.de/lehre/WS2012/KI/folien/13-machinelleslernen.pdf (Zugriff am 10.. Dezember 2020).

Sanches, Suely da Penha, und Ana Beatriz Pereira Segadilha. „Identification of factors that influence cyclists´ route choice." *Procedia - Social and Behavioral Sciences 160. XI Congreso de Ingenieria del Transporte (CIT 2014)*, 2014: 372-380.

Schiller, Christian. „Einführung in die Verkehrsnachfragemodellierung. Foliensammlung zur Vorlesung im Modul BIW 2-07 "Verkehrsinfrastrukturplanung"." 2013. https://docplayer.org/75105349-Einfuehrung-in-die-verkehrsnachfragemodellierung.html (Zugriff am 12. Oktober 2020).

Schnabel, Werner, und Dieter Lohse. *Grundlagen der Straßenverkehrstechnik und der Verkehrsplanung: Band 2 - Verkehrsplanung.* Berlin, Wien, Zürich: Kirschbaum Verlag, 2011.

Schneider, R., R. Patton, J. Toole, und C. Raborn. „Pedestrian and Bicycle Data Collection. Federal Highway Administration, U.S. Department of Transportation." 2011.

https://www.fhwa.dot.gov/policyinformation/travel_monitoring/pubs/pedbikedata.pdf (Zugriff am 6. Oktober 2020).

Schüssler, Nadine, und Kay W. Axhausen. „Identifying trips and activities and their characteristics from GPS raw data without further information." *Conference Paper ETH Zürich Research Collection.* Zürich, 2008. 29.

Schwarz, Jürg. *Logistische Regressionanalyse - Methodenberatung.* Herausgeber: Universität Zürich (UZH). 13. August 2018. https://www.methodenberatung.uzh.ch/de/datenanalyse_spss/zusammenhaenge/lreg.html#2.2._Die_Maximum-Likelihood-Sch%C3%A4tzung (Zugriff am 9. Oktober 2020).

Segadilha, Ana Beatriz Pareira, und Suely da Penha Sanches. „Analysis of bicycle commuter routes using GPS and GIS." *Procedia - Social and Behavioral Sciences 162 - XVIIICongreso Panamericano de Ingeneriá de Tránsito, Transporte y Logística*, 2014: 198-207.

Sener, I.N., N. Eluru, und C.R. Bhat. „An analysis of bicycle route choice preferences in Texas, US." *Transportation. Vol. 36*, 2009: 511–539.

Shen, Li, und Peter R. Stopher. „Review of GPS Travel Survey and GPS Data-Processing Methods." *Transport Reviews - A Transnational Transdisciplinary Journal*, 2014: 316-334.

SINUS. „Fahrrad-Monitor Deutschland 2017: Ergebnisse einer repräsentativen Online-Befragung." Herausgeber: sinus Markt- und Sozialforschung. 5. Oktober 2017. https://www.bmvi.de/SharedDocs/DE/Anlage/G/fahrradmonitor-2017-ergebnisse.pdf?__blob=publicationFile (Zugriff am 2020).

Smith, Amy, Fehr, und Peers. *Crowdsourcing Pedestrian and Cyclist Activity Data.* White Paper Series, Chapel Hill, North Carolina: Pedestrian and Bicycle Information Center, 2015.

Sobhani, Ana, S. Ali Haji Esmaeli, und Ahmad Sobhani. „On the Usse off Macchiine LLearrning Approacches fforr Impllicciitt Modelling off Cycliing Routte Choiice:: An Applliccattion of Macchiine LLearrning verssuss Patth Samplling-LLogitt Modell Frrameworrk." *IATBR 2018: 15th International Conference on Travel Behaviour Research - Santa Barbara, United States*, 2018.

Stadtradeln. *Stadtradeln - Radeln für ein gtes Klima.* 2020. https://www.stadtradeln.de/home (Zugriff am 29. Oktober 2020).

Stinson, Monique A., und Chandra R. Bhat. „A comparison of the route preferences of experienced and inexperienced bicycle commuters." *Transportation Research Board - Paper #05-1434*, 2005: 1-20.

Stopher, P. R., Q. Jiang, und C. FitzGerald. „Processing GPS data from travel surveys." *Proceeding of the 2nd International Colloqium on the Behavioural Foundations of Integrated Land-use and Transportation Models: Frameworks, Models and Applications, Toronto*, 2005.

Strava. *Strava Global Heatmap. Cycling in Germany.* 2020. https://www.strava.com/heatmap#7.23/10.40860/52.00264/blue/ride (Zugriff am 15. Oktober 2020).

Sun, Bingrong, und Byungkyu Brian Park. „Route choice modeling with Support Vector Machine." *Transportation Research Procedia 25. World Conference on Transport Research - WCTR 2016 Shanghai. 10-15 July 2016*, 2016: 1806-1814.

Thiemann-Linden, Jörg, und Tobias Mettenberger. „Fahrradportal - Forschung Radverkehr.“ 2011. https://nationaler-radverkehrsplan.de/de/literatur/forschung/forschung-radverkehr.

Ton, D., O. Cats, D.C. Duives, und S. Hoogendoorn. „How do people cycle in Amsterdam? Estimating cyclists' route choice determinants using GPS data from an urban area.“ *Transportation Research Record: Journal of Transportation Research Board*, 2017.

Treiber, Martin. „Verkehrsökonometrie - Methoden und Modelle. Skript zur Vorlesung.“ Herausgeber: insbes. im Verkehrswesen. Technische Universität Dresden. Institut für Wirtschaft und Verkehr. Lehrstuhl für Ökonometrie und Statistik. 2018. https://mtreiber.de/Vkoek_Ba/index.html#skript (Zugriff am 3. April 2019).

TSP-Dresden. *Themenstadtplan Dresden.* 2020. https://stadtplan.dresden.de/ (Zugriff am 28. Oktober 2020).

Tsui, Sheung, und Amer Said Shalaby. „An enhanced system for link and mode identification for GPS-based personal travel surveys.“ *Transportation Research Record Journal of the Transportation Research Board*, 2006.

UBA. *Potenziale des Radverkehrs für den Klimaschutz.* Dessau-Roßlau: Umweltbundesamtes, 2013.

—. *Umweltbundesamt - Radverkehr.* 2019. https://www.umweltbundesamt.de/themen/verkehr-laerm/nachhaltige-mobilitaet/radverkehr#vorteile-des-fahrradfahrens (Zugriff am 5. Oktober 2020).

UBA-c. *Struktur der Flächennutzung. Umweltbundesamt.* 2020. https://www.umweltbundesamt.de/daten/flaeche-boden-land-oekosysteme/flaeche/struktur-der-flaechennutzung#die-wichtigsten-flachennutzungen (Zugriff am 24. November 2020).

Ueda, Yusuke, Tomohiko Tsuruta, Rina Hayashi, Takeshi Hatoh, und Selichi Mita. „Path Planning Based on Support Vector Machine for Autonomous Vehicle.“ *Proceedings of the 20th ITS World Congress, Tokyo 2013.*, 2013.

Ullmann, Cornelia, und Claudia Mehlhorn. „Logistische Regression - Ein Verfahren zum Schätzen von Wahrscheinlichkeiten. Seminar: Multivariate Analysemethoden.“ Herausgeber: TU Chemnitz. 2012. https://www.tu-chemnitz.de/hsw/psychologie/professuren/method/homepages/ts/methodenlehre/LogistischeRegression.pdf (Zugriff am 30. November 2020).

Unfallatlas. *Statistikportal. Statistische Ämter des Bundes und der Länder.* 2020. https://unfallatlas.statistikportal.de/ (Zugriff am 16. November 2020).

UZH. *Methodenberatung der Universität Zürich.* 2020. https://www.methodenberatung.uzh.ch/de/datenanalyse_spss/zusammenhaenge/lreg.html (Zugriff am 04. Dezember 2020).

Valadarsky, Asaf, Michael Schapira, Dafna Shahaf, und Aviv Tamar. „A Machine Learning Approach to Routing.“ *arXiv:1708.03074v2 [cs.NI]*, 2017: 1-8.

VCD. *Verkehrsclub Deutschland - Verkehrsmittel im Vergleich.* 2020. https://www.vcd.org/themen/klimafreundliche-mobilitaet/verkehrsmittel-im-vergleich/ (Zugriff am 5. Oktober 2020).

—. *Verkehrsclub Deutschland. Radverkehrsförderung in deutschen Städten und Gemeinden.* 2016. https://fahrradfoerderung.vcd.org/startseite/ (Zugriff am 6. Oktober 2020).

VCD, Verkehrsclub Deutschland e.V. „Erfolgreiche Fahrradförderung – Verantwortung und Maßnahmen." 2019.

Waring, Jonathan, Charlotta Lindvall, und Renato Umeton. „Automated machine learning: Review of the state-of-the-art and opportunities for healthcare." *Artificial Intelligence in Medicine, Volume 104*, 2020.

White, Christopher E., David Bernstein, und Alain L. Kornhauser. „Some map matching algorithms for personal navigation assistants." *Transportation Research Part C*, 2000: 91-108.

Whittemore, Robin, und Kathleen Knafl. „The integrative review: updated methodology." *Journal of Advanced Nursing*, 2005: 546-553.

Winkler, Christian. *Ein integriertes Verkehrsnachfrage- und Bewertungsmodell - Ansatz einer Synthese von Mikrooekonomie und Verkehrsplanung.* Dresden: Technische Universität Dresden, 2011.

Wolf, Christof, und Henning Best. *Handbuch der sozialwissenschaftlichen Datenanalyse.* Wiesbaden: VS Verlag fur Sozialwissenschaften | Springer Fachmedien, 2010.

Wolf, Jean, Randall Guensler, und William Bachmann. „Elimination of the Travel Diary: Experiment to Derive Trip Purpose from Global Positioning System Travel Data." *Transportation Research Record Journal of the Transportation Research Board 1768(1)*, 2001: 125-134.

Yang, Hai, Kitamura Ryuichi, Paul P. Jovanis, Kenneth M. Vaughn, und Mohamed A. Abdel-Aty. „Exploration of route choice behavior with advanced traveler information using neural network concepts." *Transportation*, 1993: 199-223.

Zhang, Lijuan, Sagi Dalyot, Daniel Eggert, und Monika Sester. „MULTI-STAGE APPROACH TO TRAVEL-MODE SEGMENTATION AND MULTI-STAGE APPROACH TO TRAVEL-MODE SEGMENTATION AND." *Proceeding of the ISPRS. Conference on International Archives of the Photogrammetry Remote Sensing and Spatial Information Sciences XXXVIII-4/W25(4)*, 2011.

Zheng, Yu, Like Liu, Longhao Wang, und Xing Xie. „Learning Transportation Mode from Raw GPS Data for Geographic Applications on the Web." *Proceedings of the 17th International Conference on World Wide Web, WWW 2008, Beijing, China, April 21-25, 2008*, 2008.

Zimmermann, Maëlle, Tien Mai, und Emma Frejinger. „Bike route choice modeling using GPS data without choice sets of paths." *Transportation Research Part C*, 2017: 183-196.

ZIV. „Zweirad-Industrie-Verband, Wirtschaftspressekonferenz am 11. März 2020 in Berlin: Zahlen, Daten, Fakten zum Fahrradmarkt in Deutschland 2019." 2020. https://www.ziv-zweirad.de/fileadmin/redakteure/Downloads/Marktdaten/PK-2020_11-03-2020_Praesentation.pdf (Zugriff am 5. Oktober 2020).

Zong, Fang, Yu Bai, Xiao Wang, Yixin Yuan, und Yanan He. „Identifying Travel Mode with GPS Data Using Support Vector Machines and Genetic Algorithm." *information*, 2015: 212-227.

# Anhang

## Anhang 1

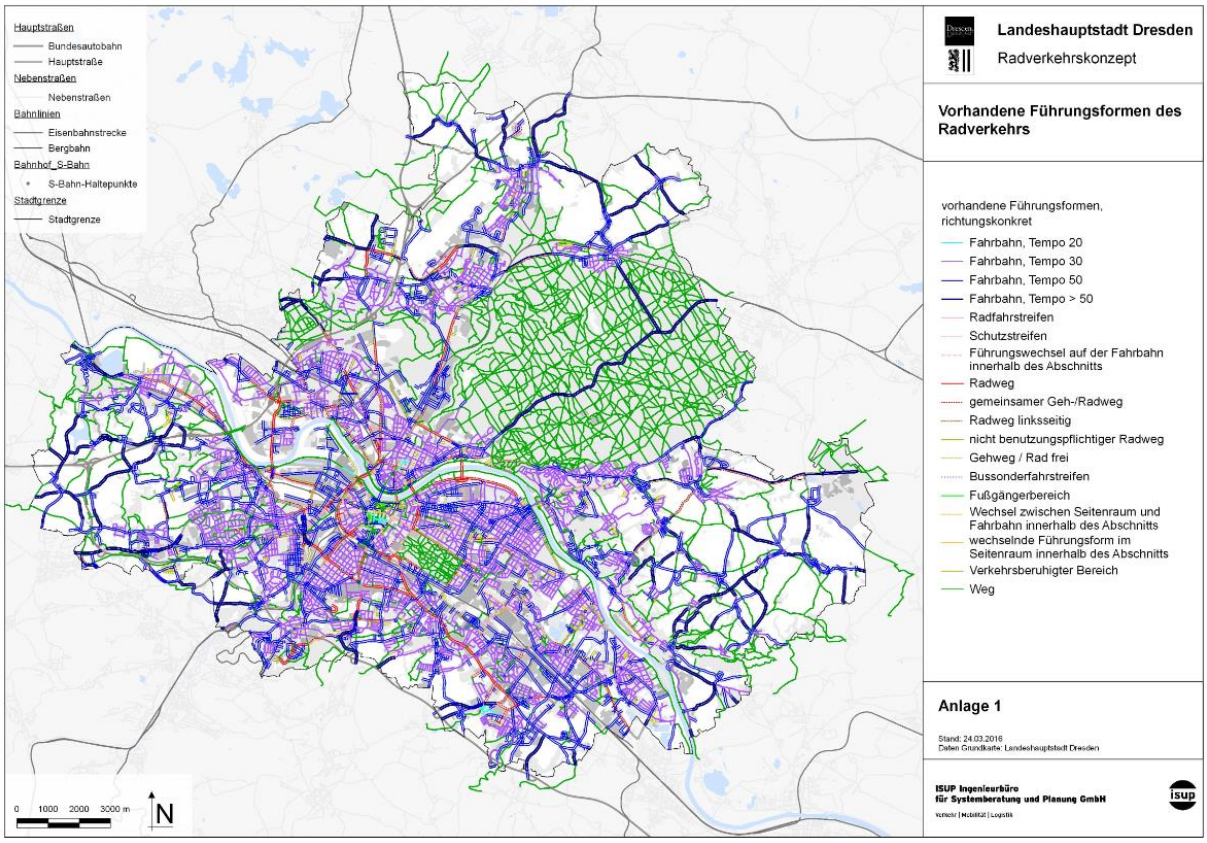


Abbildung 64: Radverkehrsnetz von Dresden inkl. der Führungsformen (Quelle: LH-Dresden-f 2017)

Anhang 2

***Ablauf der Datenaufbereitung***

Die Aufbereitung der hochgeladenen GPS-Daten erfolgt in mehreren Stufen. Abbildung 65 gibt einen Überblick über den Ablauf und die einzelnen Schritte der Datenaufbereitung. Die Berechnungen innerhalb einer Stufe baut teils auf Ergebnissen einer der vorigen Stufen auf. Die dargestellten Schritte werden daher für jeden hochgeladenen GPS-Track sukzessive ausgeführt. Sie werden in den folgenden Abschnitten detailliiert erläutert.

Abbildung 65: Schritte der Primärdatenaufbereitung

***GPS-Eingangsdaten***

Für die Datenaufbereitung werden die aus dem GPS-Sensor der Smartphones hochgeladenen Daten genutzt. Dateninhalte wurden bereit in Tabelle 4 beschrieben.

***Filtern***

In den hochgeladenen GPS-Tracks wurden vermehrt Datenpunkte identifiziert, die eine falsche zeitliche Reihung aufwiesen. Da eine nicht chronologische Reihung der GPS-Punkte in den weiteren Berechnungsschritten zu großen Problemen führen kann – eine fehlerhafte Chronologie der Koordinaten führt bspw. zu fehlerhaften Berechnungen von Geschwindigkeiten oder Beschleunigungen – werden in einem ersten Schritt die einzelnen Datenpunkte eines Tracks nach ihren Zeitstempeln (GPS_time) chronologisch sortiert.

**Filter 1** – Beinhaltet ein Track weniger als 30 GPS-Punkte bzw. beträgt die Dauer der Aufzeichnung weniger als 30 Sekunden, wird er verworfen.

Hintergrund: Bei der manuellen Plausibilisierung der Tracks wurden häufig sehr kurze Tracks entdeckt, die wahrscheinlich auf Tests der App-Nutzenden zurückgehen. Diese führten offensichtlich Funktionstest mit der STADTRADELN-App durch. Durch das kurzzeitige Aktivieren der Aufzeichnungsfunktion (Start-Button) und ein leicht zeitverzögertes Stoppen der Aufzeichnung wurden sehr kurze Tracks aufgezeichnet und übermittelt. Da diese kurzen Testaufzeichnungen keine Fahrten beinhalten, werden sie aus dem Datensatz herausgefiltert. Der Verlust von evtl. sehr kurzen Fahrten wird in Kauf genommen, um die Qualität der Daten insgesamt zu erhöhen – tatsächlich wurden im Rahmen der Plausibilisierung jedoch keine Fahrten mit einer Dauer von bis zu 30 Sekunden entdeckt.

Umsetzung: Die Umsetzung erfolgt über eine SQL-Abfrage, mit der die Anzahl der Einträge kleiner als 30 (Punkte) bzw. die zeitliche Differenz aus dem letzten und ersten Punkt ermittelt wird. Tracks, die kürzer als 30 Sekunden waren, wurden verworfen.

**Filter 2** – Alle GPS-Punkte eines Tracks mit einer geringeren Lagegenauigkeit von weniger als 35 m werden verworfen.

Hintergrund: Manche GPS-Punkte haben eine hohe Ungenauigkeit und können dadurch den Verlauf eines Tracks verzerren. Kommt es aufgrund von zu hoher Ungenauigkeit – in den Daten am Wert „Accuracy" ablesbar – zu sog. Outliern, dann verschieben sich die Koordinaten der Punkte. Bei späteren Berechnung, z.B. von Geschwindigkeiten, die über die Distanz zw. Punkten und den Zeitstempel berechnet wird, kann es dann zu starken Verzerrungen kommen, die sich auf die Eigenschaften der Routen auswirken. Daher werden Punkte mit hoher Ungenauigkeit rausgefiltert.

Stichprobeartige Analysen von Tracks mit hoher „Accuracy" (= hohe Ungenauigkeit) haben gezeigt, dass derartige Punkte sich meist am Anfang eines Tracks befinden. Ursache kann die sog. „Kaltstartproblematik" des GPS sein. Das Filtern von Punkten wirkt sich positiv auf die Qualität nachfolgender Berechnungen aus und ist unproblematisch, wenn nur ein kleiner Teil der Punkte eines Tracks betroffen ist. Die Untersuchung des vorliegenden Datensatzes hat ergeben, dass 97,9% aller Punkte eine Accuracy ≤ 3.500 besitzen (Genauigkeit von mindestens 35m). Abbildung *66*, in der alle Punkte des Datensatzes mit ihrer Accuracy aufgetragen sind, verdeutlich dies. Durch das Filtern mit dem gewählten Grenzwert gehen dementsprechend nur wenige Punkte (2,1%) aus dem Datensatz verloren. Der Informationsverlust ist also sehr gering, die Datenqualität steigt jedoch durch das Filtern.

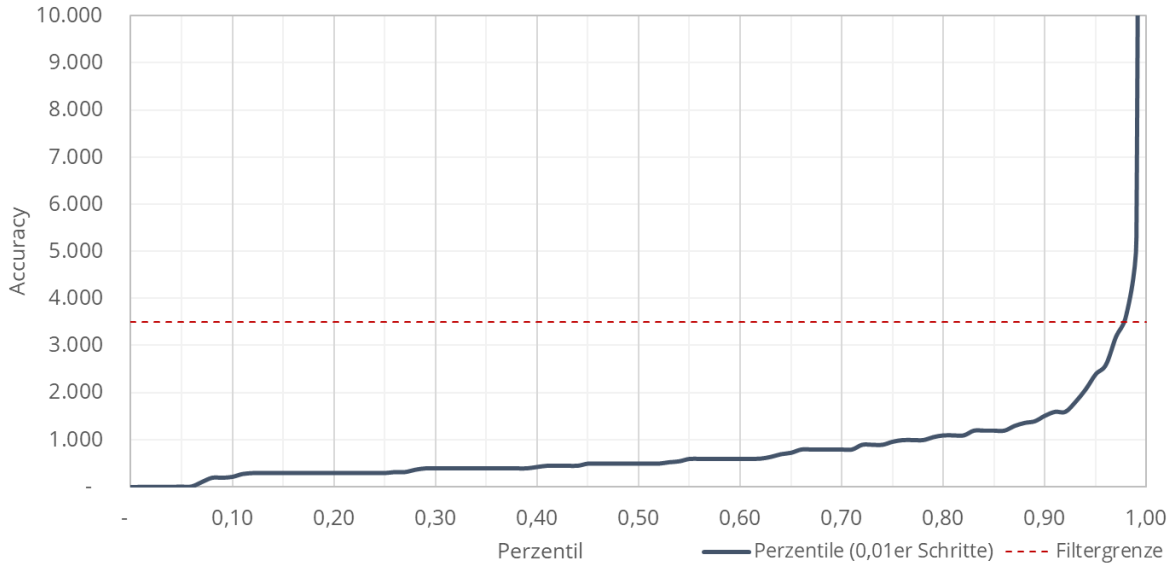


Abbildung 66: Verteilung der Accuracy der GPS-Punkte im Datensatz

Umsetzung: Die Umsetzung erfolgt über die Ansprache der Daten aus der Datenbank via SQL-Abfrage. In dieser Abfrage wird u.a. auch der Genauigkeitswert abgefragt. Ist dieser kleiner oder gleich dem gewählten Grenzwert, wird der GPS-Punkt mit einbezogen.

**Filter 3** – Fehlen in einem Track zu viele GPS-Punkte (dies äußert sich meist in Form „Lücken“ bzw. großen „Sprüngen“ in der Abfolge der Punkte), so wird er verworfen.

Hintergrund: Die Plausibilisierung der GPS-Tracks ergab, dass es während der Aufzeichnung von Fahrten häufig zum Verlust von GPS-Punkten kam. Die Gründe dafür können vielseitig sein. Nach derzeitigem Stand kommt es bei vielen Smartphones vor allem durch aggressive Energiespareinstellungen der Betriebssoftware der Smartphones oder durch das Ausbleiben von GPS-Signalen zu diesen „Lücken“ bzw. „Sprüngen“. Sie können zudem durch den Filter 2 (siehe oben) entstehen, da in diesem Schritt Punkte mit hoher Messungenauigkeit verworfen werden.

Umsetzung: Zur Identifizierung von Lücken wird ein einfacher Distanzfilter genutzt. Eine Lücke ist im Kontext des Filterns definiert als ein bestimmter Abstand zwischen zwei aufeinanderfolgenden GPS-Punkten, der einen definierten Grenzwert nicht überschreitet.

Dieser Grenzwert wird auf 50m festgelegt. Hintergrund dieser Festlegung ist, dass sich kurze Abschnitte mit fehlenden Punkten bei dem später folgenden Map Matching (siehe Kapitel 4.2.4) nicht signifikant auf den Routenverlauf auswirken. Eine Entfernung von 50m ohne GPS-Punkte lässt sich im Verlauf eines Tracks relativ gut interpretieren bzw. nachvollziehen, wohingegen ein fehlender Routenverlauf von 100m oder mehr in innerstädtischen Bereichen schlecht nachvollzogen werden kann. Die Aufzeichnung der GPS-Daten erfolgte mit einer Frequenz von 1Hz. Bei einer angenommenen Durchschnittsgeschwindigkeit von ca. 20km/h entstünde eine Distanz von 5,56m zwischen zwei GPS-Punkten. Ein Ausfall von ca. 10 Messpunkten oder mehr – dies entspricht bei der angenommenen Geschwindigkeit eine „Lücke“ von ≥ 50m im Track – wird damit von dem Filter registriert.

Die Analyse der Track-Daten hat ergeben, dass nur sehr wenige aufeinander folgende GPS-Punkte (< 1% aller Punkte im Datensatz) einen größeren Abstand als 10m aufzeigen (siehe Abbildung *67*). Insgesamt sind nur etwa 0,03% aller Distanzen zwischen zwei aufeinander folgenden Punkten größer als der gewählte Grenzwert. Abbildung *67* zeigt die geordnete Häufigkeitsverteilung der Werte und verdeutlicht den Sachverhalt. Es existieren folglich nur wenige Track im Datensatz, die durch das Filtern mit dem definierten Grenzwert verworfen würden.

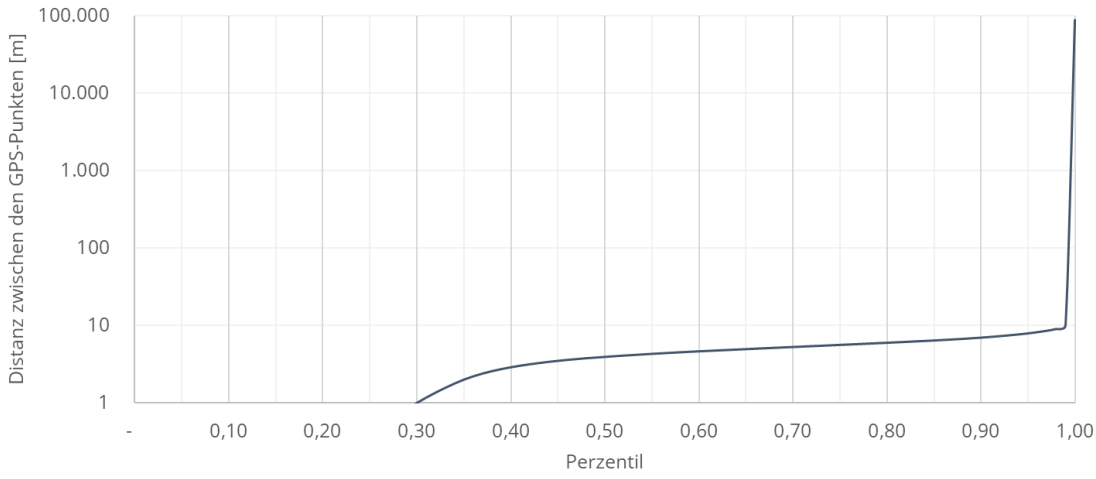


Abbildung 67: Perzentile der Distanzen zwischen den GPS-Punkten

Über den gewählten Grenzwert werden Lücken in einem Track, die länger als 50m sind, identifiziert und markiert. Treten mehrere Lücken in einem Track auf, so kann die Gesamtroute bei zu vielen und zu großen Lücken nicht mehr hinreichend genau beschrieben werden. Daher wird im Anschluss an die Identifizierung aller Lücken in einem Track die Summe aus den Distanzen der Lücken gebildet. Macht ihr Anteil mehr als 10% der Gesamtlänge eines Tracks (relativer Grenzwert) aus oder beträgt sie unabhängig von der Gesamtlänge eines Tracks mehr als 500 Meter (absoluter Grenzwert), so wird ein Track verworfen. Mit steigender Wegelänge würde die Fehlertoleranz durch einen reinen relativen Grenzwert (10%) zunehmen und damit deutlich größere Lücken zulassen (z.B. 1km Lücke bei 10km Fahrtweite). Um dies zu umgehen und auch bei längeren Fahrten eine Mindestqualität zu gewährleisten, wird zusätzlich dieser absolute Grenzwert (500m) genutzt. Er „deckelt“ sozusagen den relativen Grenzwert. Der Grenzwert von 500 m wurde gewählt, weil sich bei Routen mit großen Distanzen und der Verwendung eines rein relativen Grenzwerts leicht große Lücken im Routenverlauf ergeben können, die nicht ohne Weiteres nachvollzogen werden können. Darüber hinaus führen große Lücken im Track zu Problemen in den nachfolgenden Berechnungsschritten.

Im Ergebnis verbleiben nach dem Anwenden der unterschiedlichen Filter alle GPS-Tracks im Datensatz, die a) werktägliche Fahrten sind, b) mindestens 30 GPS-Punkte enthalten, c) deren GPS-Punkte über ein Mindestmaß an Lagegenauigkeit verfügen und die d) nicht allzu große Lücken im Routenverlauf aufweisen.

***Daten-Glättung***

In den vorigen Schritten wurden die Track-Daten bereinigt (z.B. wurden Punkte mit hoher Lageungenauigkeit entfernt). Es können jedoch auch kleinere Abweichungen, z.B.

bei den Lagekoordinaten (lat, lon), zu Abweichungen und Fehlern führen (z.B. bei den aus den Koordinaten berechneten Geschwindigkeiten). Eine Datenglättung kann helfen, Ausreißer zu nivellieren. Bei der Datenglättung geht es darum, dass Werte über ihre Vorgänger und Nachfolger interpretiert und gewichtet werden. Dabei werden jedoch nicht die GPS-Koordinaten geglättet, sondern die aus ihnen resultierenden Geschwindigkeiten – korrekte Geschwindigkeitswerte ohne Ausreißer sind im weiteren Verlauf der Datenaufbereitung notwendig. Die Glättung der Geschwindigkeiten ist notwendig, weil Geschwindigkeitswerte stark variieren können – jedoch nicht so stark, dass sie in einem vorgeschalteten Filterprozess ersetzt wurden. Eine Glättung der Geschwindigkeiten führt dazu, dass der Geschwindigkeitsverlauf „weicher" wird. Abbildung *68* illustriert diesen Sachverhalt und stell geglättete und nicht geglättete Geschwindigkeiten (Rohdaten) gegenüber.

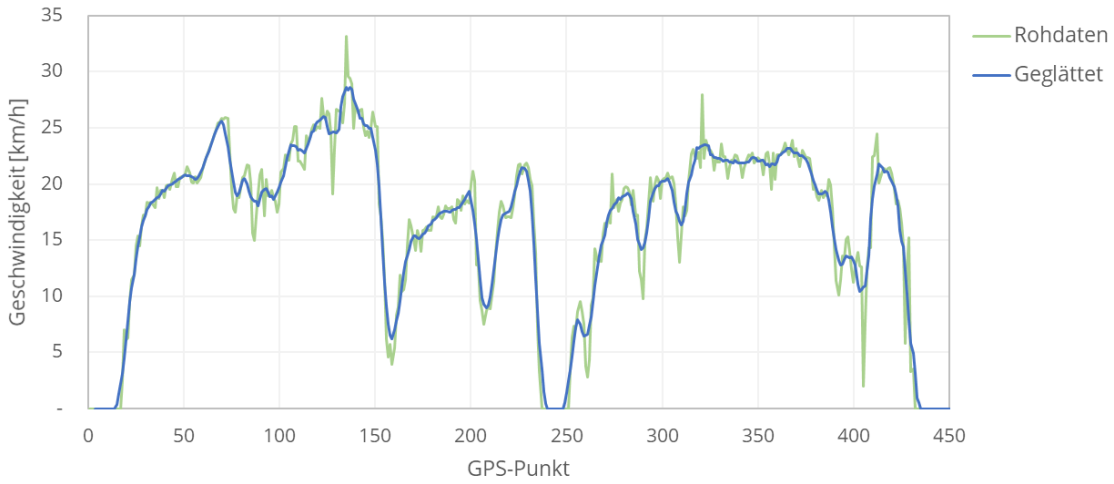


Abbildung 68: Vergleich des Geschwindigkeitsverlauf von nicht geglätteter und geglätteter Geschwindigkeit

Die Glättung birgt große Vorteile für die Dateninterpretation und die weiteren Berechnungen. Grundlage der Glättung sind die Geschwindigkeiten zwischen zwei GPS-Punkten, die zunächst berechnet werden. Ihre Berechnung erfolgt nach

$$Lat_{RAD} = Lat_{GRAD} * \frac{\pi}{180} \tag{46}$$

$$d_{1-n} = 2 * R_{Erde} * \sin^{-1} \sqrt{\sin(\frac{Lat_{n+1} - Lat_n}{2})^2 + \cos Lat_n * \cos Lat_{n+1} * \sin(\frac{Lon_{n+1} - Lon_n}{2})^2} \tag{47}$$

$$V = \left(\frac{S}{t_{n+1} - t_n}\right) \quad \text{mit} \quad S = \sum_{P1}^{Pn} d_{1-n} \tag{48}$$

Formel (46) beschreibt die Umrechnung der Koordinaten von $Lat_{Grad}$ (in Grad) in das Bogenmaß $Lat_{Rad}$, das für die Berechnung der Distanzen zwischen den Punkten gebraucht

wird. Die Umrechnung für die Koordinaten der geographischen Breite von $Lon_{Grad}$ in $Lon_{Rad}$ erfolgt analog. Mit Formel (47) werden anschließend anhand der umgerechneten Längen- und Breitengradinformationen im Bogenmaß die Entfernungen (Großkreisentfernung = Haversine) zwischen zwei aufeinanderfolgenden GPS-Punkten (1 und 2) berechnet. Im Gegensatz zur Euklidischen Distanz birgt die Nutzung der Haversinen-Distanz eine höhere Genauigkeit, weil sie die Erdkrümmung berücksichtigt. Über Formel (48) werden anschließend über die Distanz $s$ sowie der Zeitdifferenzen $t_{n+1}$-$t_n$ zwischen den jeweiligen GPS-Punkten $n$ und $n+1$ die Geschwindigkeiten $v$ berechnet.

Die berechneten Werte gehen anschließend in die Glättung ein. Da eine einfache Glättung (z.B. Gleitendes Mittel) zwar simpel und robust, jedoch nicht sehr effektiv gegenüber großen Ausreißern ist, wird eine gewichtete Glättung über die Datenpunkte durchgeführt. Für die Glättung wird die Gauß'sche Glättung genutzt. Sie verteilt die Gewichte entsprechend einer Normalverteilung ausgehend vom Berechnungspunkt. Die Berechnung erfolgt nach

$$\tilde{c}(t) = \frac{\sum_j (w(t_j) \cdot c(t_j))}{\sum_j w(t_j)} \tag{49}$$

mit $c \in x, y, z$ und $c\ (t_j)$ als Roh-Wert zum Zeitpunkt $t_j$. $W(t_j)$ ist die Gauß'sche Kernfunktion und berechnet sich nach

$$w(t_j) = \exp - \frac{(t - t_j)^2}{2\sigma^2} \tag{50}$$

mit $\sigma$ als Kernbandbreite von 10 Sekunden, die aus einer 15-sekündigen Glättungsreichweite resultiert. Diese Zeit gilt als Zeitrahmen für eine Verhaltensänderungen (Schüssler und Axhausen 2008).

***Track-Segmentierung und Verkehrsmittelerkennung***

Die Sichtung der hochgeladenen GPS-Tracks hat aufgezeigt, dass viele der Tracks teils mehrere Fahrten und/oder weitere Aktivitäten beinhalteten. Der Grund ist vermutlich, dass die App-Nutzenden zum Fahrtende vergaßen, die Aufnahme zu stoppen. Durch das fortlaufende Tracking wurden fortwährend GPS-Daten an Aktivitäten-Orten aufgezeichnet, die Datengrundlage wesentlich beeinflussen. Abbildung *69* zeigt beispielhaft, wie sich ein derartiges Ereignis auf die Ergebnisse der aufgezeichneten Daten

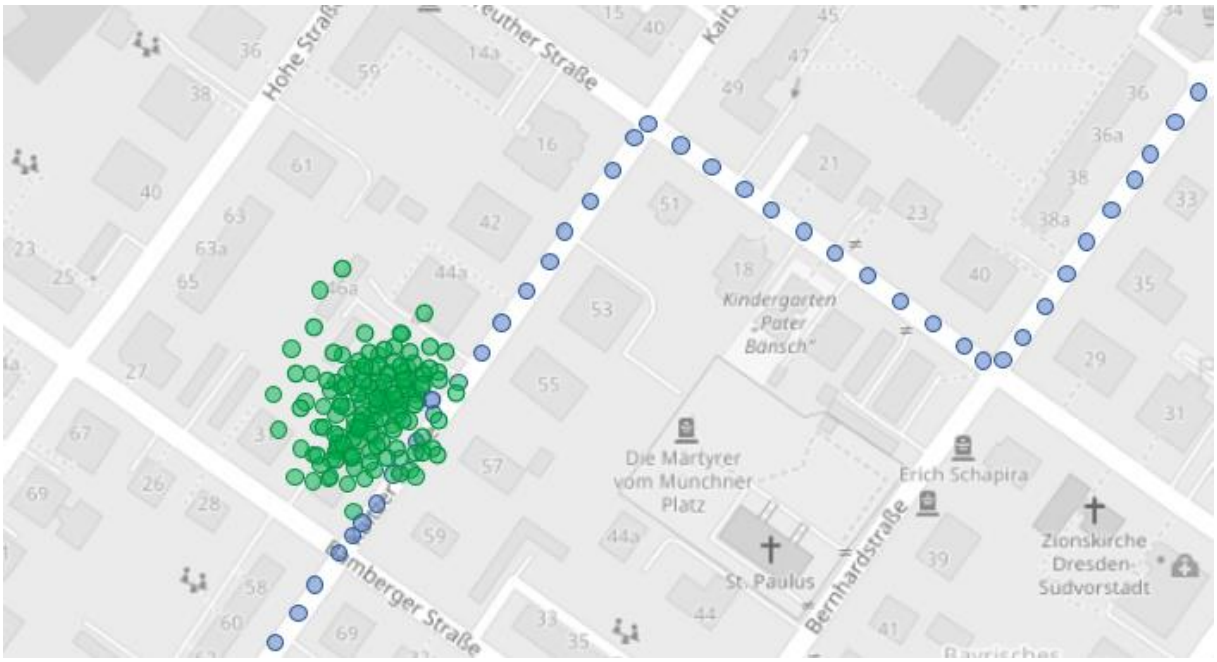


Abbildung 69: Punkte einer aufgezeichneten Fahrt (blau)
inkl. Zwischenhalt an einem Aktivitäten-Ort (grün)

Das dauerhaft fortgesetzte Tracking führt dazu, dass der aufgezeichnete GPS-Track zwei Fahrten und eine Aktivität beinhaltet, die als solche zwar visuell erkennbar sind. Da eine manuelle und visuelle Prüfung der erhobenen Daten bei zehntausenden Datensätzen jedoch nicht möglich ist, müssen diese Fahrten und Aktivitäten im Rahmen einer automatisierten Datenaufbereitung erkannt werden.

Darüber hinaus kann das fortgesetzte Tracking dazu führen, dass neben der eigentlichen Radfahrt auch Fahrten mit anderen Verkehrsmitteln (z.B. bei der Kombination von Fahrrad und ÖV) mit aufgezeichnet und übertragen wurden. Aus diesem Grund muss im Rahmen der Datenaufbereitung eine Überprüfung und, wenn nötig, Segmentierung des GPS-Tracks in „Fahrten" und „Aktivitäten" sowie eine Bestimmung des Verkehrsmittels „Rad" innerhalb der erkannten „Fahrten" erfolgen. Abbildung *70* verbildlicht den Prozess vereinfacht. Für die einzelnen Entscheidungsprozesse werden komplexere Modelle genutzt, die im Folgenden detaillierter beschrieben werden.

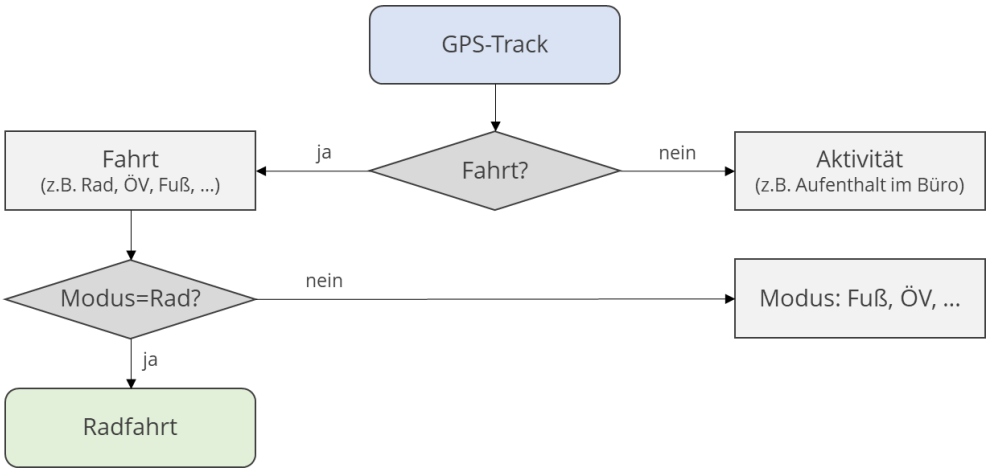


Abbildung 70: Vereinfachte Veranschaulichung der Entscheidungsprozesse zur Erkennung von Radfahrten im GPS-Datensatz

**Track-Segmentierung**

Um andere Aktivitäten, die keine Fahrten darstellen, im den hochgeladenen Daten zu erkennen, wird im Rahmen der sog. Track-Segmentierung für jeden einzelnen GPS-Punkt eines Tracks bestimmt, ob er Teil einer Fahrt oder einer Aktivität (an einem Aktivitäten-Ort) ist. Für die Erkennung solcher Aktivitäten innerhalb eines Tracks können verschiedene Parameter (z.B. Geschwindigkeits-Grenzwerte, Zeit-Grenzwerte, Änderungen der Richtungsvektoren, Track-Point-Dichten) genutzt werden. Eine Übersicht zu potentiell nutzbaren Parametern und Verfahren sind in Gonga, et al. 2014, Kohla 2014, Schüssler und Axhausen 2008 Zong, et al. 2015 Zhang, et al. 2011, Biljecki, Ledoux und van Oosterom 2013 und Shen und Stopher 2014 beschrieben. Die beschriebenen Verfahren nutzen für die Fahrtenerkennung eine Art gleitendes Zeitfenster, in dem bestimmte Parameter (z.B. Geschwindigkeiten oder zurückgelegte Distanzen) für jeden einzelnen berechnet und überprüft werden. Für den vorliegenden Ansatz wurden die folgende Parameter gewählt:

p) **Geschwindigkeit**, weil während eines längeren Aufenthalts an einem Ort (Aktivität) meist keine Bewegung erfolgt, wodurch in der Regel eine bestimmte durchschnittliche Geschwindigkeit unterschritten wird. Die Geschwindigkeitsverteilung der Punkte an Aktivitäten-Orten unterscheidet sich deutlich von der Geschwindigkeitsverteilung der Punkte während einer Fahrt (siehe Abbildung *71*)

q) **Distanz**, weil im Gegensatz zu einer Fahrt bei einer Aktivität an einem Ort kaum Strecke zurückgelegt wird. Etwaige Strecken können lediglich durch Signalspringen zu Stande kommen. Die zurückgelegten Distanzen sind im Mittel daher wesentlich geringer (siehe Abbildung *72*).

r) **Richtungsvektoren**, weil es bei einem Aufenthalt an einem Ort durch Signalstörungen zu einem „Hin-und-Herspringen“ der GPS-Punkte und damit verbunden zu einer überdurchschnittlich häufigen Änderung der Richtungsvektoren zwischen den einzelnen Punkten kommt (siehe Abbildung *73* und Abbildung *74*)

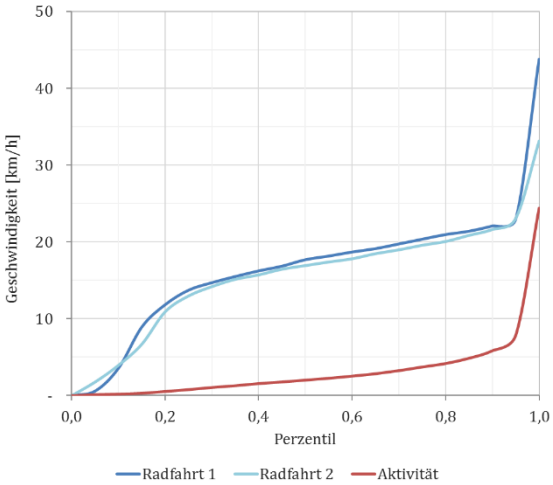


Abbildung 71: Beispielhafte Darstellung der Unterschiede in der Geschwindigkeitsverteilung von Fahrten und Aktivitäten

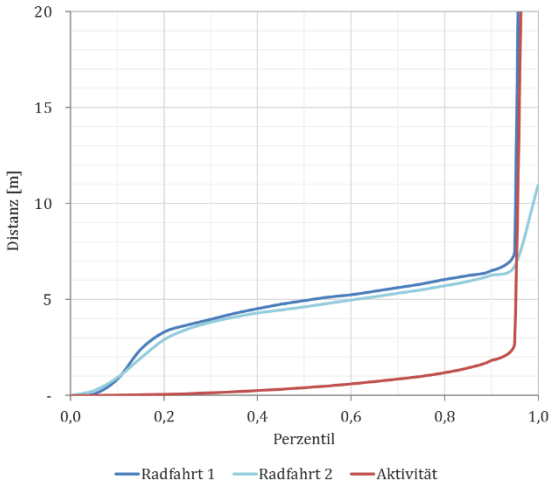


Abbildung 72: Beispielhafte Darstellung der Unterschiede in der Distanzverteilung von Fahrten und Aktivitäten

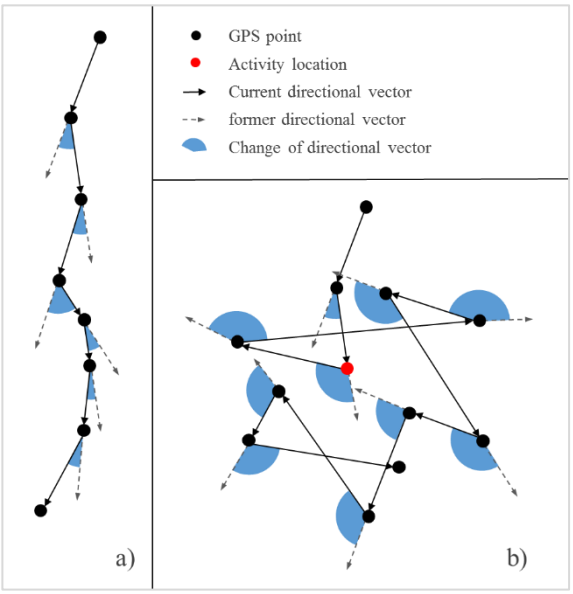


Abbildung 73: Beispielhafte Darstellung der Änderung der Richtungsvektoren bei einer Fahrt (a) und einer Aktivität (b)

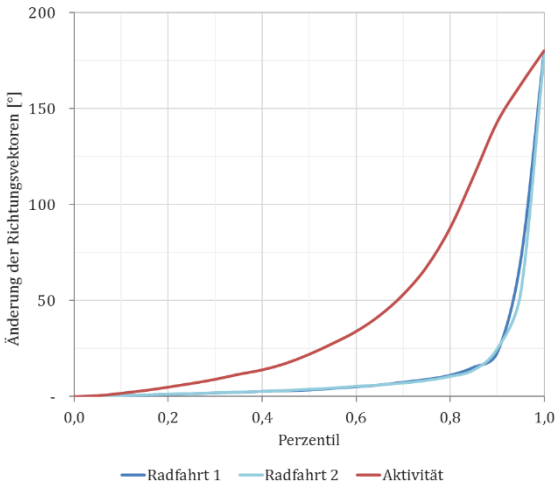


Abbildung 74: Beispielhafte Darstellung der Verteilung der Änderung der Richtungsvektoren bei Radfahrten und Aktivitäten

Für die Track-Segmentierung wurde entsprechend der obigen Schilderungen ein Algorithmus mit gleitendem Zeitfenster entwickelt, der anhand der Geschwindigkeit, der

zurückgelegten Distanz sowie der Änderung der Richtungsvektoren für jeden einzelnen Punkt eines Tracks bestimmt, ob dieser Punkt Teil einer Fahrt ist oder nicht.

In bereits durchgeführten Studien wurden unterschiedlich breite Zeitfenster genutzt. In den Arbeiten von Wolf, Guensler und Bachmann 2001, Tsui und Shalaby 2006, Stopher, Jiang und FitzGerald 2005 und Schüssler und Axhausen 2008 nutzen bspw. ein 120 Sekunden breites Zeitfenster, während in den Studien von Axhausen, et al. 2004, Bohte und Maat 2009 und Gong, et al. 2012 höhere Werte verwendet wurden (300s, 180s und 200s). Im vorliegenden Ansatz wurde ein Zeitfenster von 180s genutzt. Dies ist zwar 60 Sekunden länger als das nach den Richtlinien für Lichtsignalanlagen (RiLSA) empfohlenen maximal Umlaufzeit für Radfahrende an Lichtsignalanlagen (LSA) von 120s (vgl. FGSV 2015), berücksichtigt damit aber besser Verzögerungen (bspw. durch verlangsamte Reaktion der Probanden oder durch Bevorrechtigung und Anmeldung des ÖPNV an LSA geregelten Knotenpunkten).

Da die einzelnen Eingangsgrößen (Geschwindigkeiten, Distanzen, Richtungsänderungen) jedoch streuen können und diese Streuung sowohl während der Fahrt als auch an einem Aktivitäten-Ort auftreten, werden die genannten Parameter zu dem neuen Parameter τ kombiniert.

Der Parameter τ stellt eine Art Überhöhung dar und hilft dadurch, Fahrten und Aktivitäten besser voneinander zu unterscheiden. Abbildung *75* verdeutlicht dies beispielhaft für eine Fahrt (linksseitig der gestrichelten Linie) mit anschließendem Aufenthalt an einem Aktivitäten-Ort (rechtsseitig der gestrichelten Linie). Die Berechnung von τ erfolgt nach:

$$\tau_i = v_i * d_i * \frac{1}{\Delta head_i} \tag{51}$$

mit $v_i$ als Geschwindigkeit am Punkt *i*, $d_i$ als Distanz zwischen den Punkten *i* und *i-1* und $\Delta head_i$ als Änderung des Richtungsvektors zwischen den Punkten *i* und *i-1*. Die Geschwindigkeit $v_i$ und die Distanz $d_i$ (Haversinen-Distanz) sind Ergebnisse vorheriger Berechnungsschritte (siehe Formel (52) bis (56)). Die Änderung der Richtungsvektoren $\Delta head_i$ berechnet sich nach:

$$\Delta head_i = \begin{cases} \left|\dot{\alpha}_\iota - \dot{\alpha}_\jmath\right| & \text{für } \Delta\dot{\alpha}_{\iota\jmath} \leq 180 \\ \left|\left|\dot{\alpha}_\iota - \dot{\alpha}_\jmath\right| - 360\right| & \text{für } \Delta\dot{\alpha}_{\iota\jmath} > 180 \end{cases} \tag{52}$$

mit

$$\dot{\alpha_{ij}} = \begin{cases} 90 - \alpha & , \text{für } \alpha > 0 \ \cap \ \alpha \ \leq 90 \\ 360 - (\alpha - 90) & , \text{für } \alpha > 90 \ \cap \alpha \leq 180 \\ \sqrt[2]{(\alpha - 90)^2} & , \text{für } \alpha \leq 0 \ \cap \ \alpha \geq -90 \ \cup \ \alpha < -90 \ \cap \ \alpha \geq -180 \end{cases} \tag{53}$$

und

$$\alpha = ARCTAN2\ (x, y) * \left(\frac{180}{\pi}\right) \tag{54}$$

$$x = \cos\left(lat_j * \frac{\pi}{180}\right) * \sin\left(lon_j * \frac{\pi}{180}\right) - lon_i * \frac{\pi}{180} \tag{55}$$

$$y = \cos\left(lat_i * \frac{\pi}{180}\right) * \sin\left(lat_j * \frac{\pi}{180}\right) - \sin\left(lat_i * \frac{\pi}{180}\right) * \cos\left(lat_j * \frac{\pi}{180}\right) * \cos\left(\left(lon_j * \frac{\pi}{180}\right) - \left(lon_i * \frac{\pi}{180}\right)\right) \tag{56}$$

Nach dem Durchlauf der Berechnungen liegt für jeden GPS-Punkt *i* ein Wert für $\tau$ vor. Anschließend überprüft der Algorithmus den mittleren Wert für $\tau$ in dem definierten Zeitfenster. Liegt dieser unter einem definierten Grenzwert (τ = 1,5; Wert entstammt der Datenanalyse), so ist der GPS-Punkt Teil einer Fahrt, sonst Teil einer Aktivität.

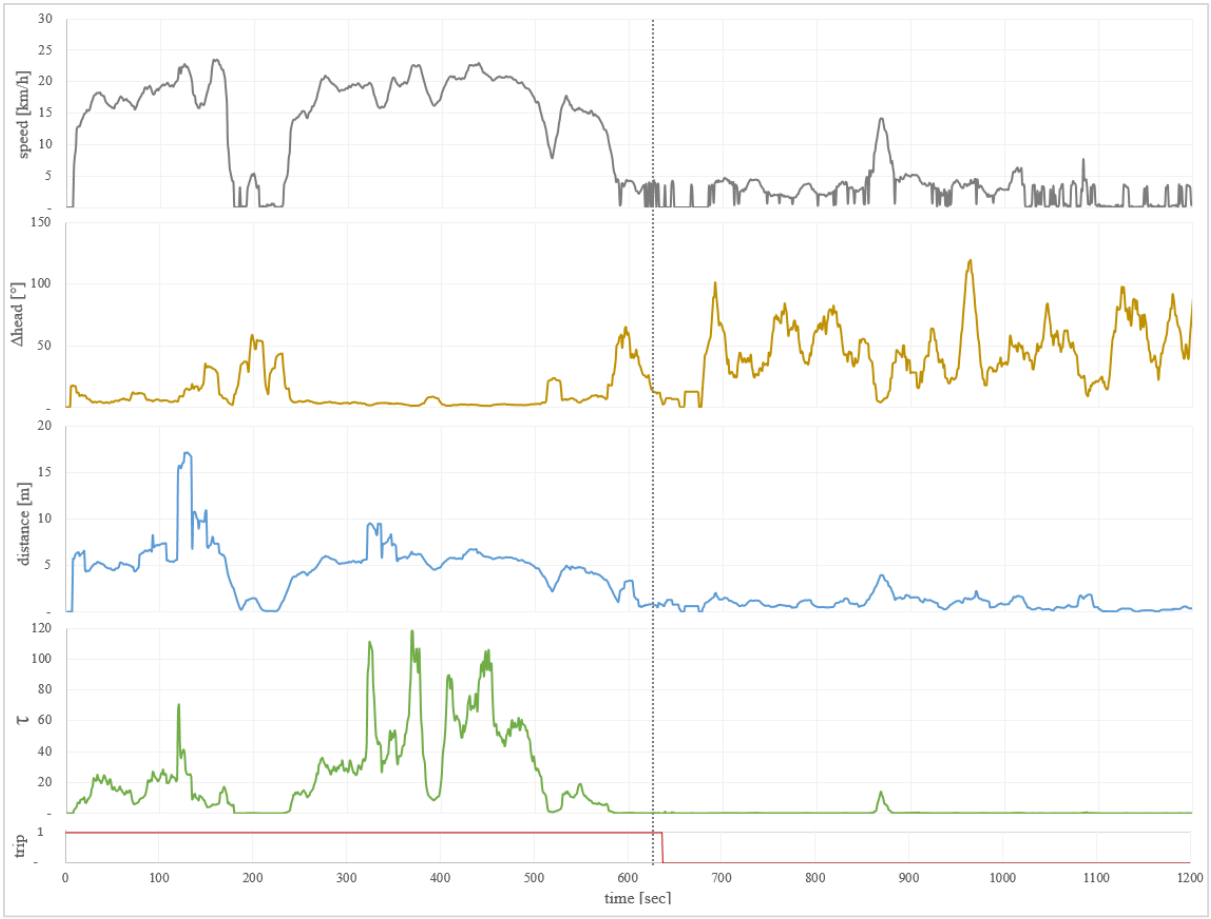


Abbildung 75: Darstellung von Geschwindigkeit, Richtungsvektoränderung, Distanz und TAU

Endergebnis des Berechnungsschritts ist, dass jeder hochgeladene Track (falls notwendig) in 1-n Fahrten oder Aktivitäten segmentiert wird. Damit liegen am Ende der bisherigen Berechnungen einzelne Fahrten vor sowie alle Aktivitäten, die keine Fahrten sind. Diese werden am Ende des beschriebenen Berechnungsschrittes herausgefiltert und in folgenden Berechnungen nicht weiter berücksichtigt.

### Verkehrsmittelerkennung

Um in einem weiteren Schritt die Radfahrten in dem GPS-Datensatz bestimmen zu können, wurde in Anlehnung an bereits existierende Modelle und auf Basis eigener GPS-Daten-Auswertung ein regelbasiertes Modell zur Verkehrsmittelerkennung entwickelt. Der entwickelte Entscheidungsbaum basiert im Wesentlichen auf der Bestimmung des Verkehrsmittels über Kennwerte unterschiedliche Eingangsparameter.

Für die Zuordnung einer Fahrt zu einem bestimmten Verkehrsmittel werden verkehrsmittelspezifische Kennwerte benötigt. Zur Ermittlung dieser Kennwerte wurden GPS-Tracks (n=406) unterschiedlicher Verkehrsmittel (Fuß, Rad, Bus, Tram, S-Bahn) erho-

ben und analysiert. Die Analysen zeigten auf, dass sich Geschwindigkeitsverteilungen (genauer: unterschiedliche Quantile der Geschwindigkeit), Beschleunigungen sowie Fahrtweiten und Umwege-Faktoren sehr gut für die Verkehrsmittelerkennung eignen.

Die Abbildung *76* bis Abbildung *79* verdeutlichen am Beispiel der erhobenen Daten die unterschiedlichen Verteilungen von Geschwindigkeiten, Beschleunigungen und Umwege-Faktoren für die verschiedenen Verkehrsmittel. Es wird deutlich, dass sich bspw. die unterschiedlichen Quantile der Geschwindigkeiten gut eignen, um die Verkehrsmittel anhand ihrer Geschwindigkeitsprofile zu unterschieden.

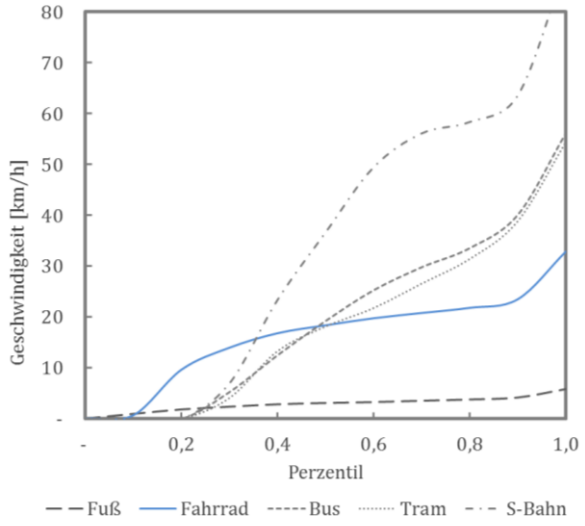


Abbildung 76: Mittlere Geschwindigkeitsverteilung unterschiedlicher Verkehrsmittel

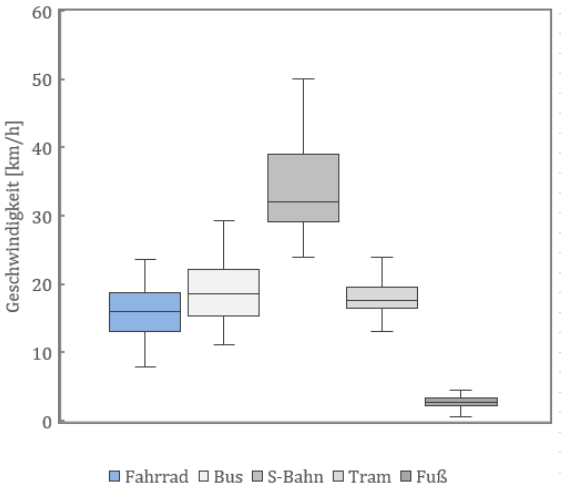


Abbildung 77: Boxplot-Diagramm der mittleren Geschwindigkeiten der Verkehrsmittel

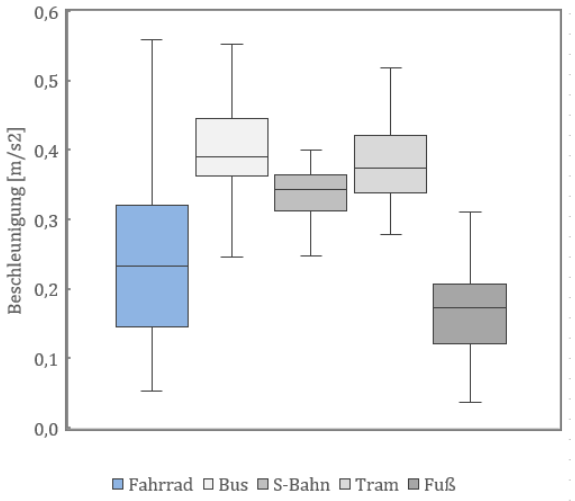


Abbildung 78: Boxplot-Diagramm der mittleren Beschleunigung unterschiedlicher Verkehrsmittel

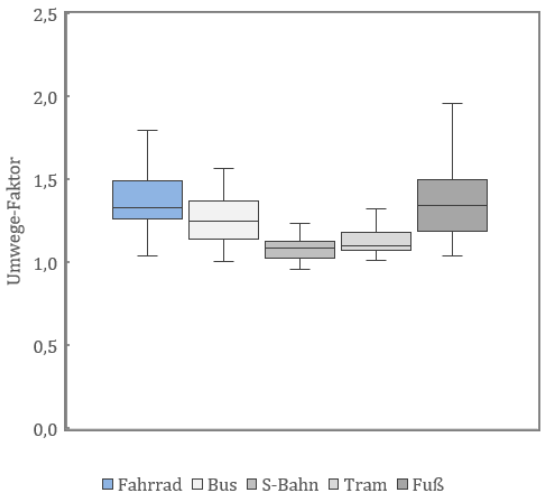


Abbildung 79: Boxplot-Diagramm der Umwege-Faktoren unterschiedlicher Verkehrsmittel

Ähnlich differenzierte Verteilungen ergeben sich bei der Betrachtung der absoluten Beschleunigungswerte. Fahrtweiten und Umwege-Faktoren können darüber hinaus helfen, Radsport-, Freizeit- und Rundfahrten zu erkennen. Diese sind in der Regel deutlich

länger sind als alltägliche Pendelfahrten und/oder weisen hohe Umweg-Faktoren auf, weil die gewählten Routen z.B. nicht den kürzesten Wegen entsprechen oder gar den gleichen Start- und Endpunkt haben.

Aufgrund des Aufwands bei der Datenhaltung und begrenzter Rechenkapazitäten wurden keine weiteren Sensor-Daten (z.B. des Beschleunigungssensors oder Magnetometers) genutzt, sondern lediglich auf Daten des GPS-Sensors zurückgegriffen.

Für die Verkehrsmittelerkennung wurde ein Entscheidungsbaummodell entwickelt. Es handelt sich dabei um einen mehrstufigen Baum, mit drei Entscheidungsebenen. Als Eingabe dienen, jeweils in unterschiedlichen Stufen, die folgenden Kenngrößen einer Fahrt:

s) 20%-Quantil der Geschwindigkeit
t) 80%-Quantil der Geschwindigkeit
u) 90%-Quantil der Geschwindigkeit
v) Distanz
w) Umweg-Faktor

Diese verschiedenen Attribute werden für jeden Identifizierten Trip berechnet. Das n-te Quantil wird jeweils berechnet, indem der Wert ausgegeben wird, der an n-ter Stelle der geordneten Datenreihe steht.

Die Trip-Distanz berechnet sich aus der Summe der zwischen den Punkten eines Trips berechneten Distanzen nach:

$$d_f = \sum_{x=1}^{n} d_{x_{ij}} \tag{57}$$

mit $d_f$ als Fahrt-Distanz und $d_{xij}$ als Distanz zwischen zwei Punkten $x_i$ und $x_j$ einer Fahrt $f$.

Der Umweg-Faktor $UF_f$ einer Fahrt berechnet sich aus der während einer Fahrt zurückgelegten Distanz $d_f$ und der Luftliniendistanz $dl_f$ zwischen Anfangs- und Endpunkt der Fahrt. Die Berechnung erfolgt dementsprechend nach:

$$UF_f = \frac{d_f}{dl_f} \tag{58}$$

Die Luftliniendistanz $dl_f$ wird entsprechend der Formeln (46) bis (48) für die Anfangs- und Endpunkte einer Fahrt bestimmt.

Nachdem die Kennwerte für jede Fahrt berechnet wurden, können diese für die Verkehrsmittelerkennung genutzt werden. Das Hauptziel der Verkehrsmittelerkennung bestand nicht darin möglichst alle existierenden Verkehrsmittel zu erkennen, sondern vor

allem darin alltägliche Radfahrten zu identifizieren. Daher wurden lediglich die zu bestimmenden „Modi“ a) Fuß, b) Rad-Sport, c) Rad und d) Sonstige gewählt. Die Auswahl begründet sich folgendermaßen.

a) Durchgeführte Wege zu Fuß lassen sich anhand der geringen Geschwindigkeiten relativ einfach und sicher von allen anderen Modi unterscheiden und erkennen (siehe Abbildung *76* und Abbildung *77*).
b) Da bei der Aktion STADTRADELN teils auch Freizeitfahrten (Radtouren) durchgeführt werden, für die Analyse jedoch hauptsächlich alltägliche Wege mit dem Fahrrad genutzt werden sollen, werden auch Freizeitfahrten erkannt und herausgefiltert. Freizeitfahrten zeichnen sich vor allem durch größere Fahrtweiten und/oder hohe Umweg-Faktoren (z.B. max. bei Rundfahrten mit gleichem Start- und Zielpunkt) aus.
c) Alle Radfahrten (außer den Freizeitfahrten) sollen für die Analyse genutzt werden
d) Alle anderen Fahrten (z.B. Zug, Tram, Bus Pkw o.ä.) werden der Kategorie „sonstige“ zugeordnet. Eine detailliertere Unterscheidung ist im Rahmen der vorliegenden Arbeit nicht von Interesse.

Für die Erkennung der gewünschten Radfahrten werden im Entscheidungsbaum, beginnend am sog. Wurzelknoten, unterschiedliche die Entscheidungsregeln des Baumes angewendet auf eine Fahrt und ihre Eigenschaften angewendet. Abbildung *80* verdeutlicht den Entscheidungsbaum mit seinen Entscheidungsknoten (Rauten) und den beschriebenen Verkehrsmittel-Kategorien a) bis d).

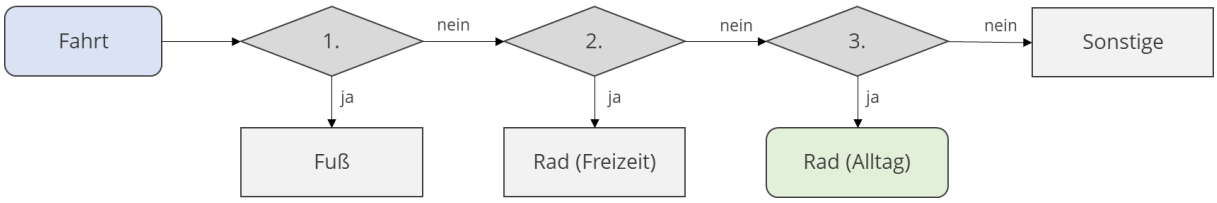


Abbildung 80: Entscheidungsbaum der Verkehrsmittelerkennung

An jedem Knoten werden ein oder mehrere Eigenschaften (Kennwerte) einer Fahrt abgefragt. Der Kennwert einer Fahrt entscheidet über den weiteren Verlauf im Entscheidungsbaum und damit über die Zuordnung zu einer der Verkehrsmittel-Kategorien oder den weiteren Weg zum nächsten Folgeknoten. In Abhängigkeit von den Einzelentscheidungen an den Knoten kann die Abfolge von Abfragen schließlich zu einer finalen Zuordnung führen.

Die Zuordnung hängt zum einen von den Eigenschaften (Kennwerte) einer Fahrt ab. Zum anderen sind die Abfragen in den Knoten 1. bis 3. sowie die festgelegten Parameter

in den Abfragen, die gegen die Kennwerte einer Fahrt geprüft werden, entscheidend. Dementsprechend ist die Zuordnung einer Fahrt zu einer Kategorie eine Funktion der einzelnen oder teils kombinierten Abfragen in den Knoten. Die Abfragen in den Knoten lauten wie folgt:

1. $wenn\ A = wahr, dann\ „Fuß“, sonst\ 2.$
2. $wenn\ B \cap (C \cup D) \cap F = wahr, dann\ Rad\ (Freizeit), sonst\ 3.$
3. $wenn\ E \cap F = wahr, dann\ „Rad“, sonst\ „sonstige“$

mit

$$A = v80_{Fahrt} \leq 8\ km/h$$
$$B = v20_{Fahrt} \geq 10\ km/h$$
$$C = D_{Fahrt} > 30\ km$$
$$D = UF_{Fahrt} > 3$$
$$E = v90_{Fahrt} \leq 35\ km/h$$
$$F = v80_{Fahrt} < 50\ km/h$$

und

$v80_{Fahrt}$ – 80%-Quantil der Geschwindigkeit des Trips
$v20_{Fahrt}$ – 20% Quantil der Geschwindigkeit des Trips
$D_{Fahrt}$ – Distanz des Trips
$UF_{Fahrt}$ – Umweg-Faktor des Trips
$v90_{Fahrt}$ – 90%-Quantil der Geschwindigkeit des Trips

Die Werte für die Abfragen innerhalb der einzelnen Knoten haben sich aus den Analysen der erhobenen Daten ergeben.

Am Ende Verkehrsmittelerkennung wird schließlich über die Modi gefiltert, sodass ein bereinigter Datensatz zur Verfügung steht, der lediglich (alltägliche) Radfahrten beinhaltet. Die Datenaufbereitung wurde mit einem zufällig ausgewählten und manuell plausibilisierten Datensatz getestet. Es erfolgte anschließend in mehreren Iterationen eine Validierung und iterative Anpassung der Grenzwerte, sodass GPS-Tracks kaum fehlerhaft segmentiert und Fahrten keinem falschen Verkehrsmittel zugeordnet wurden. Die Genauigkeit der Verkehrsmittelerkennung lag schließlich bei rund 88%.

***Filter 5***

Ein abschießender Filter bereinigt den verbliebenen Datensatz von Fahrten, die 90 oder weniger GPS-Punkte enthalten. Hintergrund für die Anwendung des Filters sind vor allem technische Restriktionen bei der Implementierung der Track-Segmentierung. Das gleitende Zeitfenster von 180 Sekunden, das für die Track-Segmentierung genutzt wird, lässt sich nicht ab dem ersten Punkt zu Beginn eines Tracks aufbauen, sondern erst ab

Punkt 91 eines Tracks (Mitte des Zeitfensters). Dadurch ist die die Erkennung einer Aktivität erst ab diesem Punkt in der Reihe eines GPS-Tracks möglich. Das führt dazu, dass die ersten 90 Punkte einer Aktivität noch als Fahrt klassifiziert werden, selbst wenn es sich nicht um eine Fahrt handelt. Diese Punkte werden durch den Filter beseitigt.

***Ergebnis der Primärdatenaufbereitung***

Das Ergebnis der Primärdatenaufbereitung sind bereinigte GPS-Daten, die nur noch Radfahrten beinhalten. Sie stehen von diesem Zeitpunkt für weitere Schritte zur Verfügung.

## Anhang 3

Zur Bestimmung des Zusammenhangs zwischen den Radverkehrsmengen aus den GPS-Daten und den Verkehrsstärken (DTV) der Dauerzählstellen wurde eine lineare Regressionsanalyse in SPPS (Version 27) durchgeführt. Die Ergebnisse der Analyse weisen einen starken ($R^2$ = 0,83) und hoch signifikanten (sign. = 0,00) linearen Zusammenhang zwischen den beiden Datensätzen aus. Aus diesem Ergebnis kann geschlussfolgert werden, dass ein statistischer Zusammenhang zwischen den GPS-Daten und den Referenzdaten besteht. Der Zusammenhang kann vor allem an Querschnitten mit hohen Verkehrsstärken als gesichert angesehen werden.

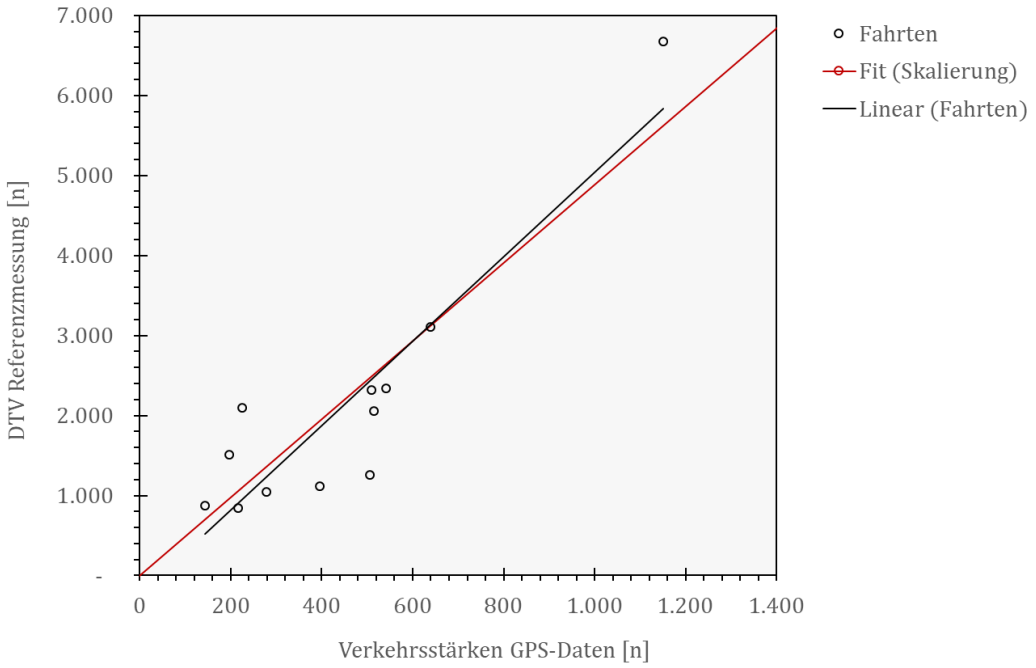


Abbildung 81: Gegenüberstellung von Verkehrsstärken aus den Referenz- und den GPS-Daten

Abbildung 81 verdeutlicht den Zusammenhang grafisch. Die aus der Analyse resultierende Regressionsgleichung (y = 5,2801*X - 237,35) kann jedoch nicht direkt für das Hochskalieren der Fahrten auf den $DTV_{Rad}$ genutzt werden, da der zweite Term der Gleichung bei deren Anwendung auf die GPS-Verkehrsstärken negative Werte ergeben könnten (siehe schwarze Gerade). Daher muss die Regressionsgerade im Nullpunkt fixiert werden (rote Gerade). Dadurch ergibt sich ein Skalierungsfaktor von 4,89, der für die Skalierung der Radverkehrsstärken auf den $DTV_{Rad}$ genutzt wird. Im Ergebnis liegen damit für alle Strecken im Verkehrsnetz Werte zum $DTV_{Rad}$ vor.

## Anhang 4

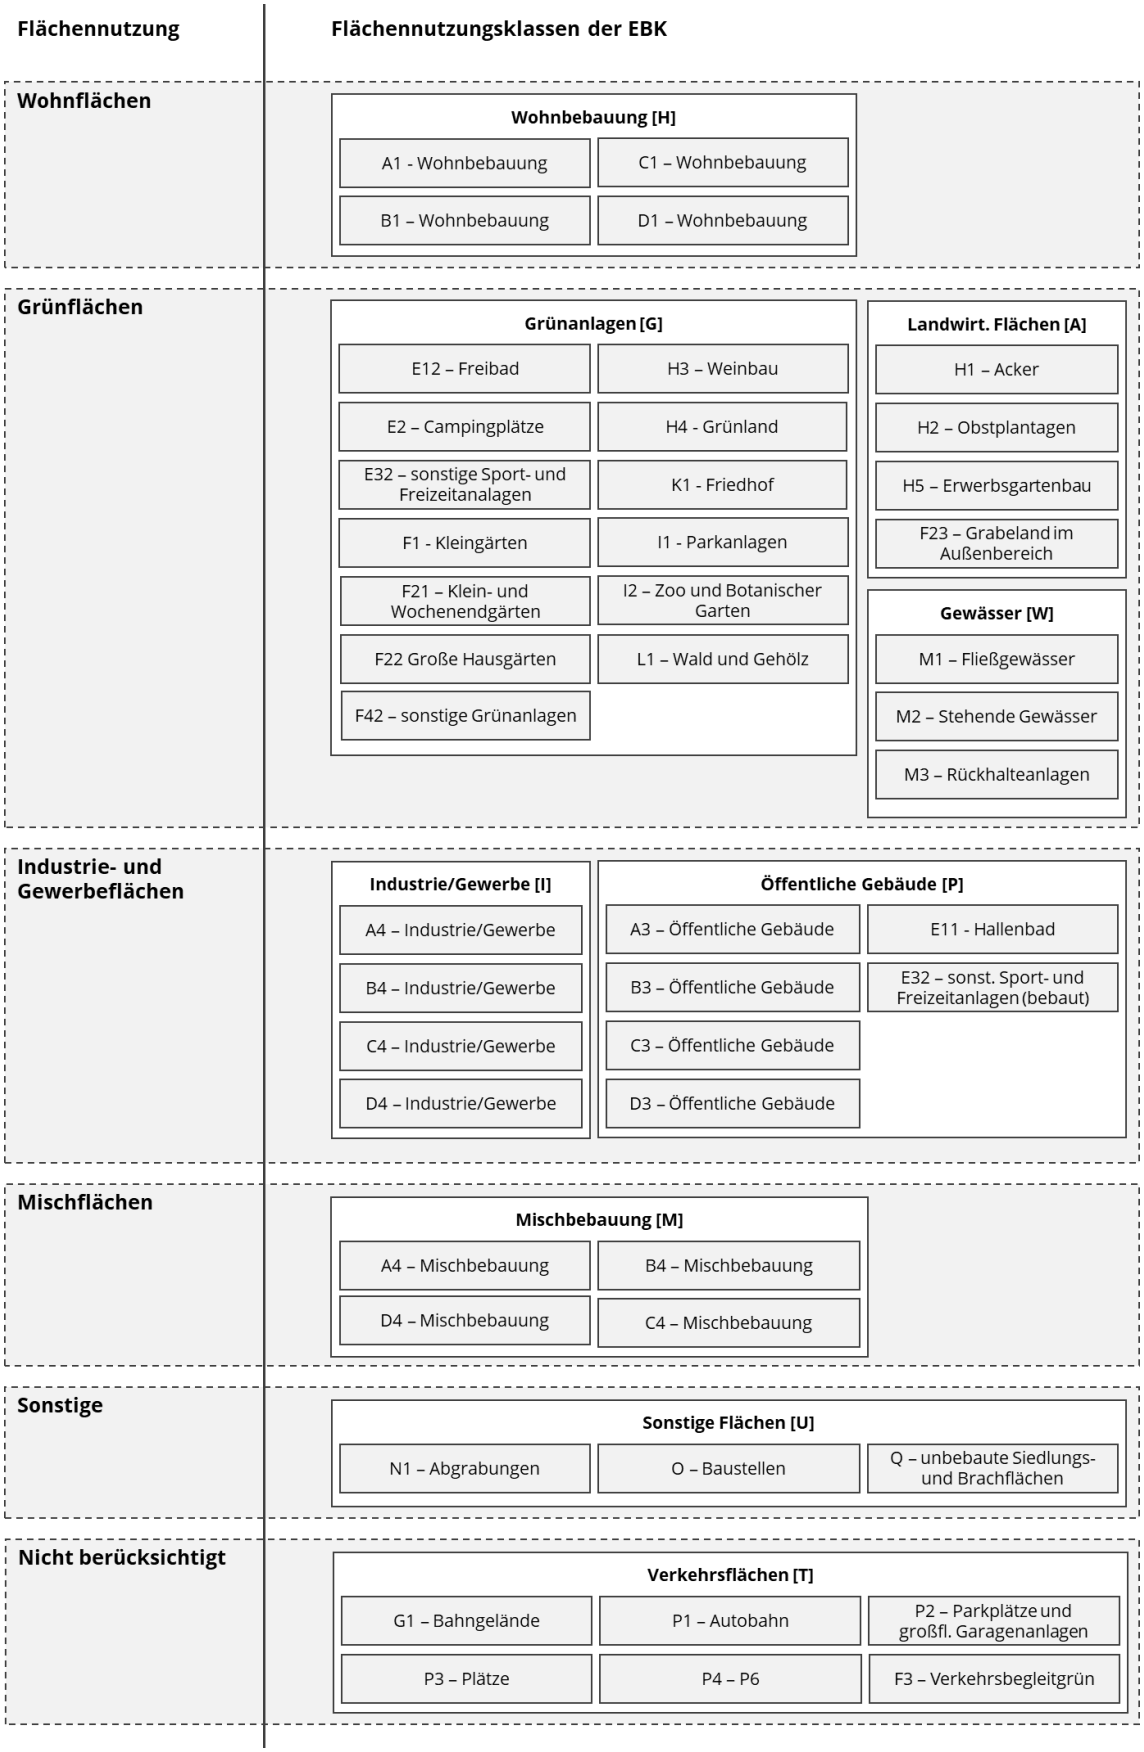


Abbildung 82: Aggregation der Flächennutzungsklassen

## Anhang 5

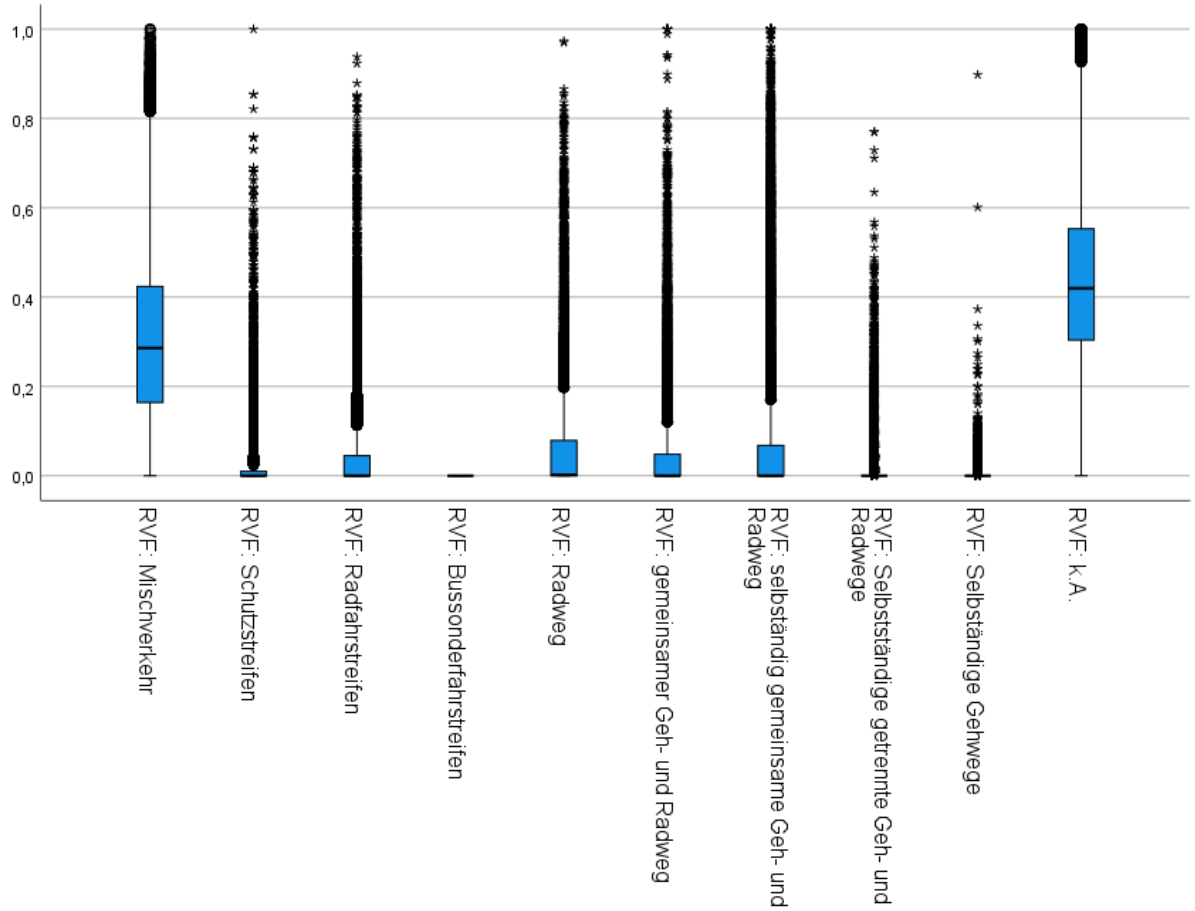


Abbildung 83: Verteilung der Radverkehrsführungsform

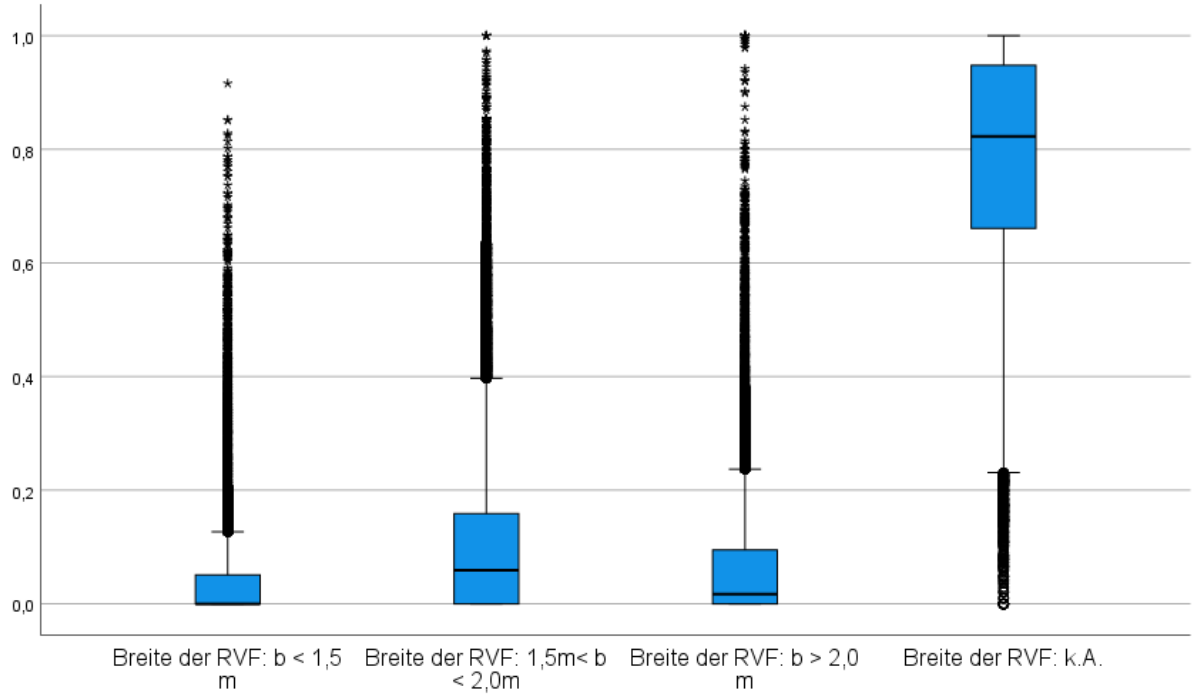


Abbildung 84: Verteilung der Breite der Radverkehrsführungsform

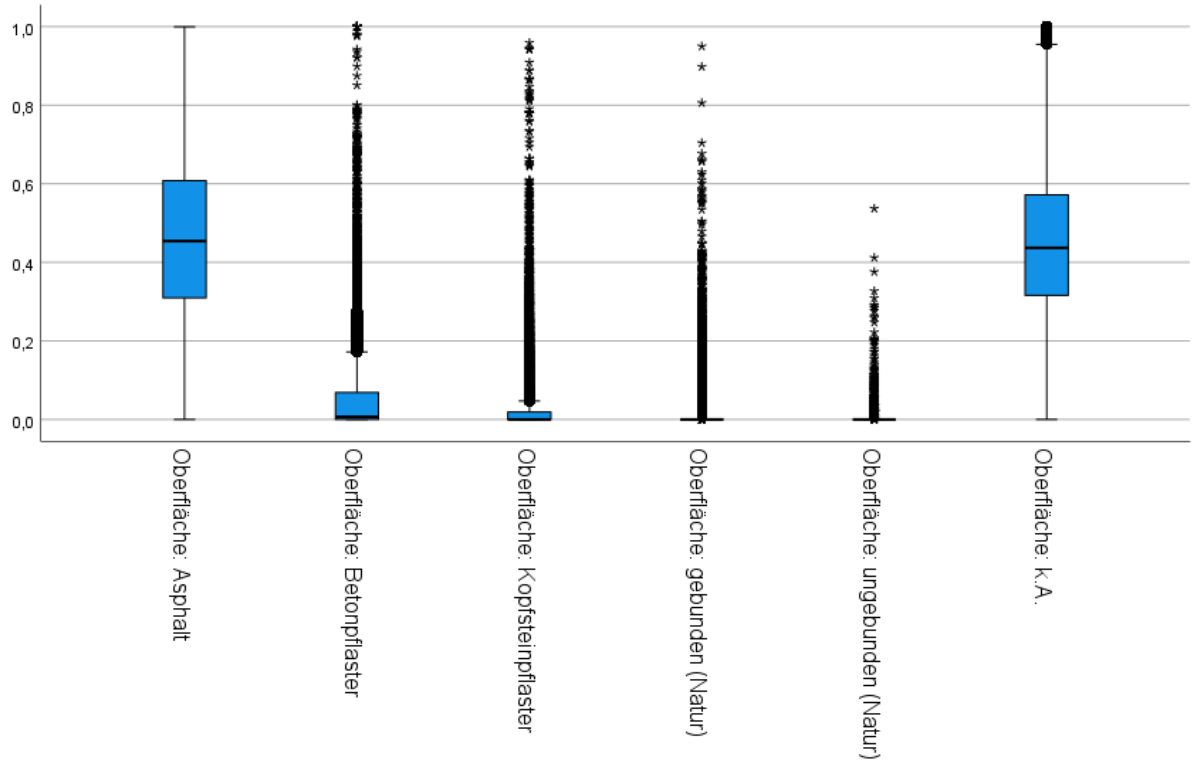


Abbildung 85: Verteilung der Oberflächenbeschaffenheit

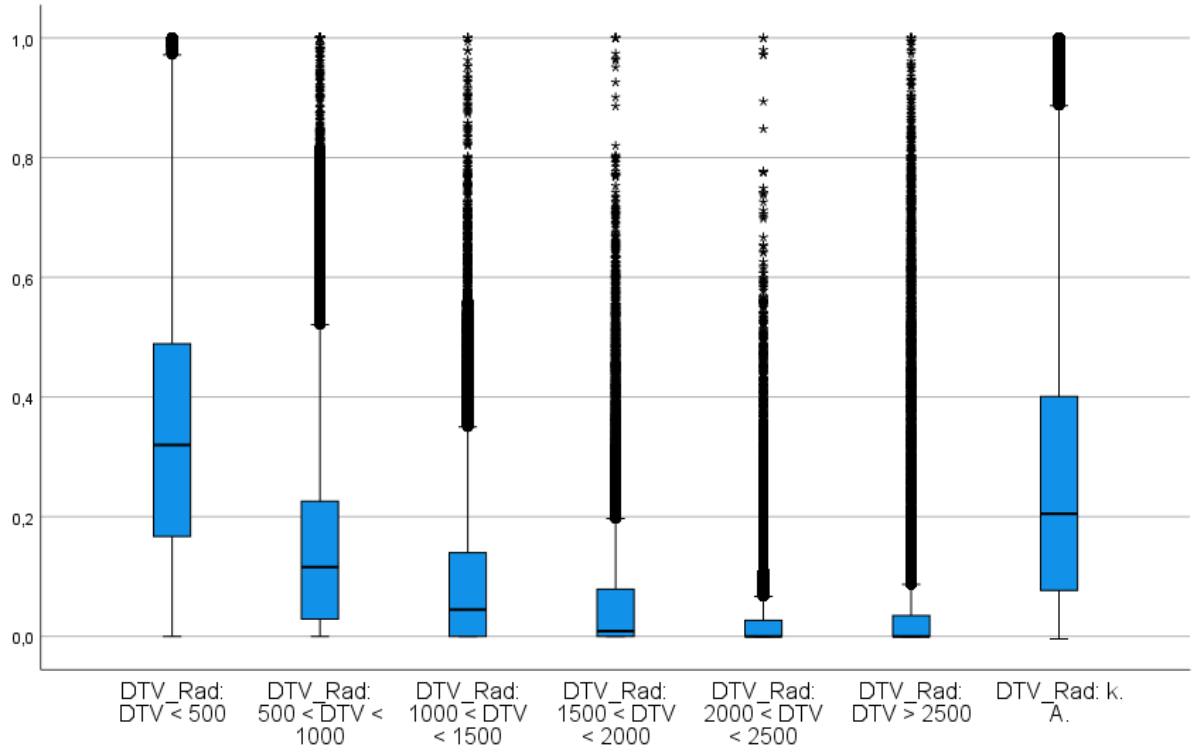


Abbildung 86: Verteilung der Radverkehrsstärken

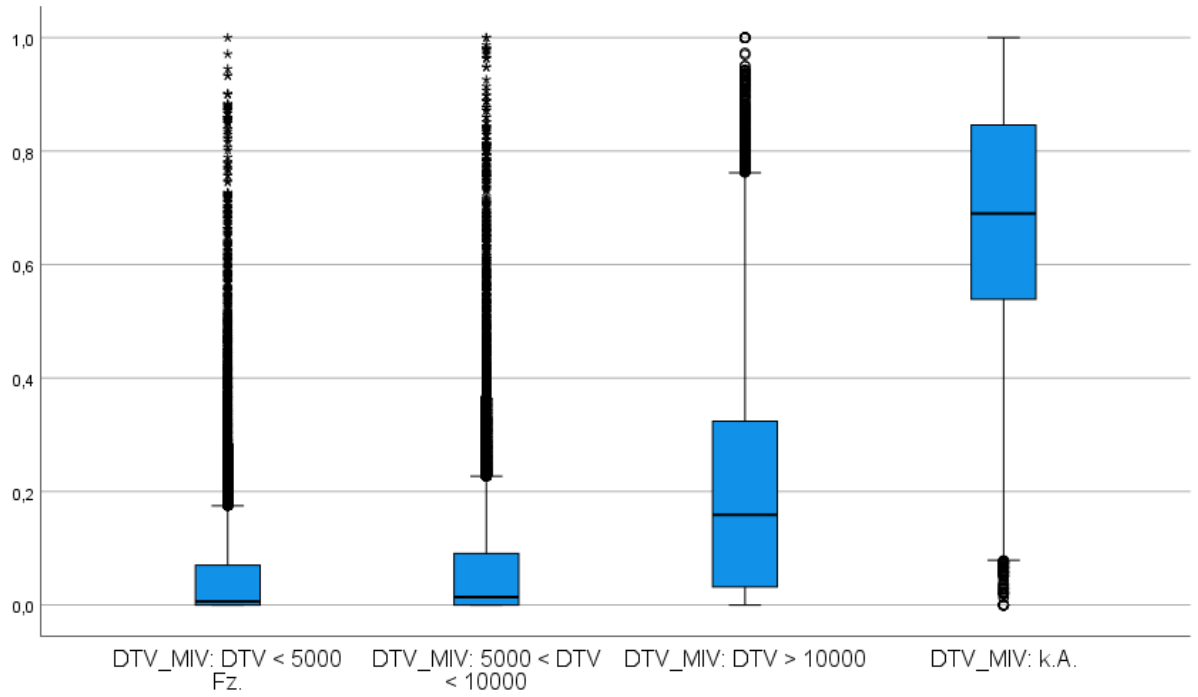


Abbildung 87: Verteilung der Kfz-Verkehrsstärken

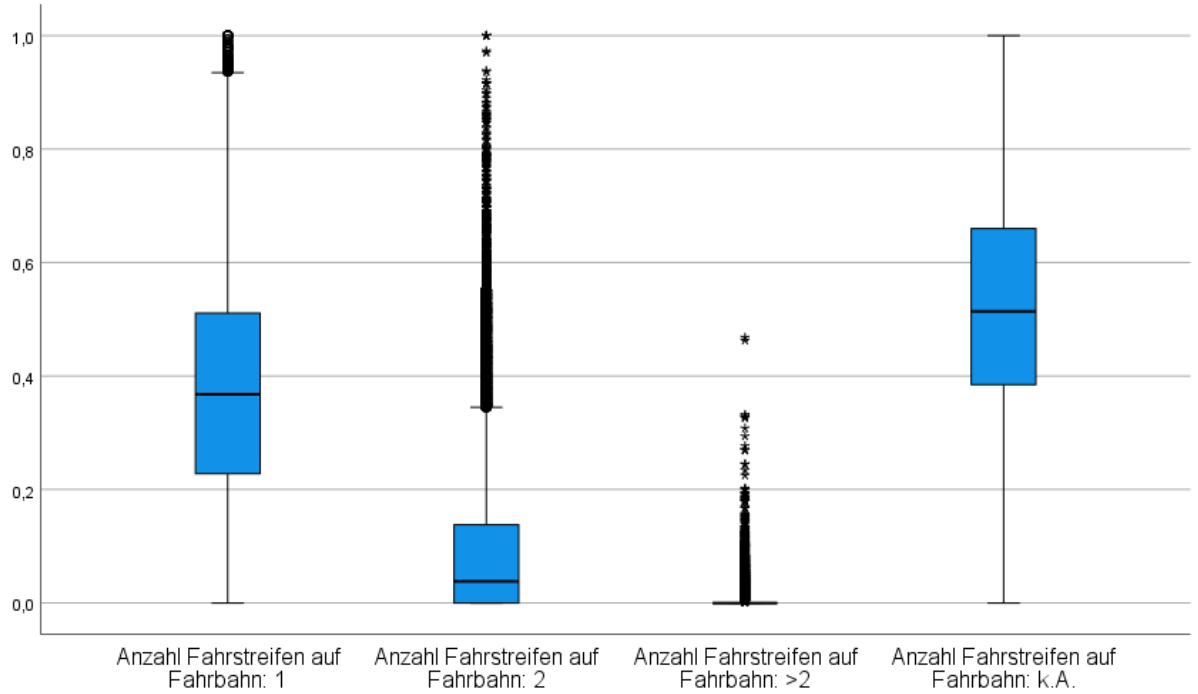


Abbildung 88: Verteilung der Anzahl der Fahrstreifenanzahl

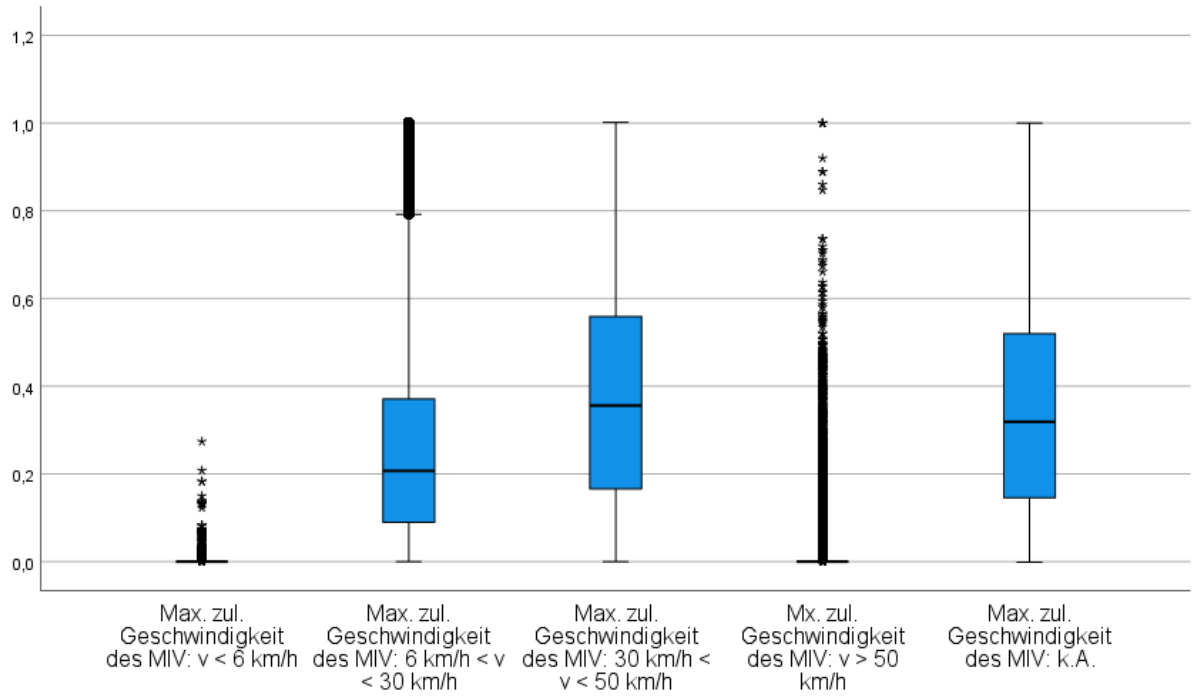


Abbildung 89: Verteilung der maximal zulässigen Geschwindigkeit des Kfz-Verkehrs

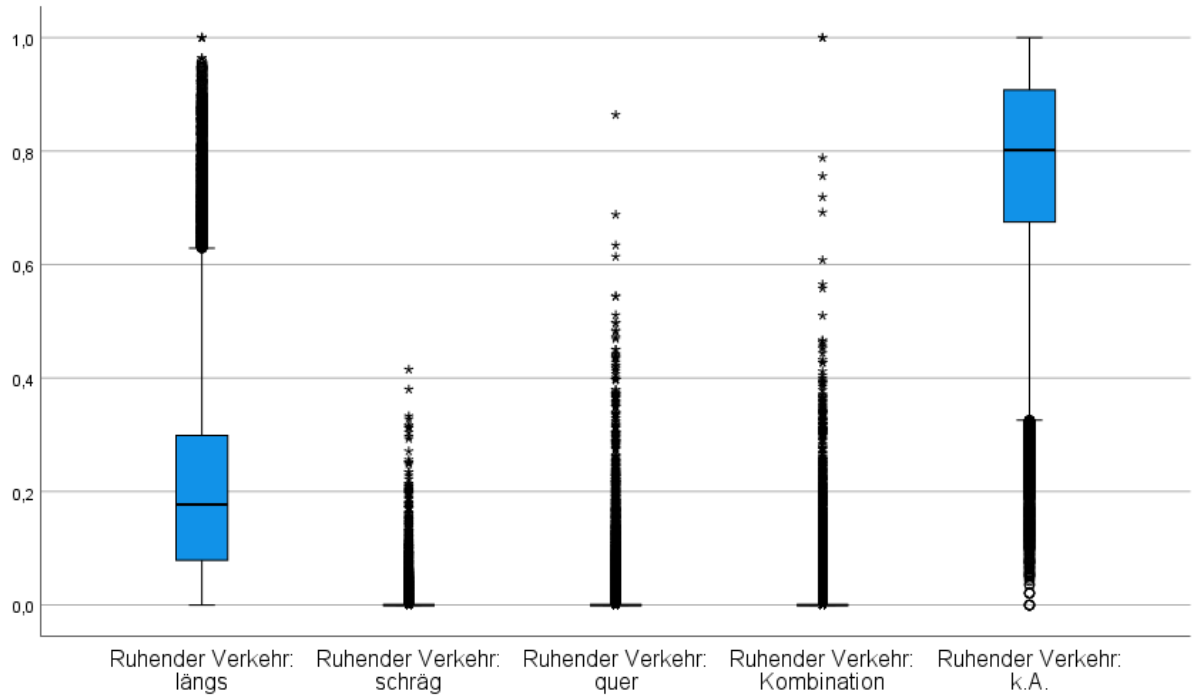


Abbildung 90: Verteilung des ruhenden Verkehrs

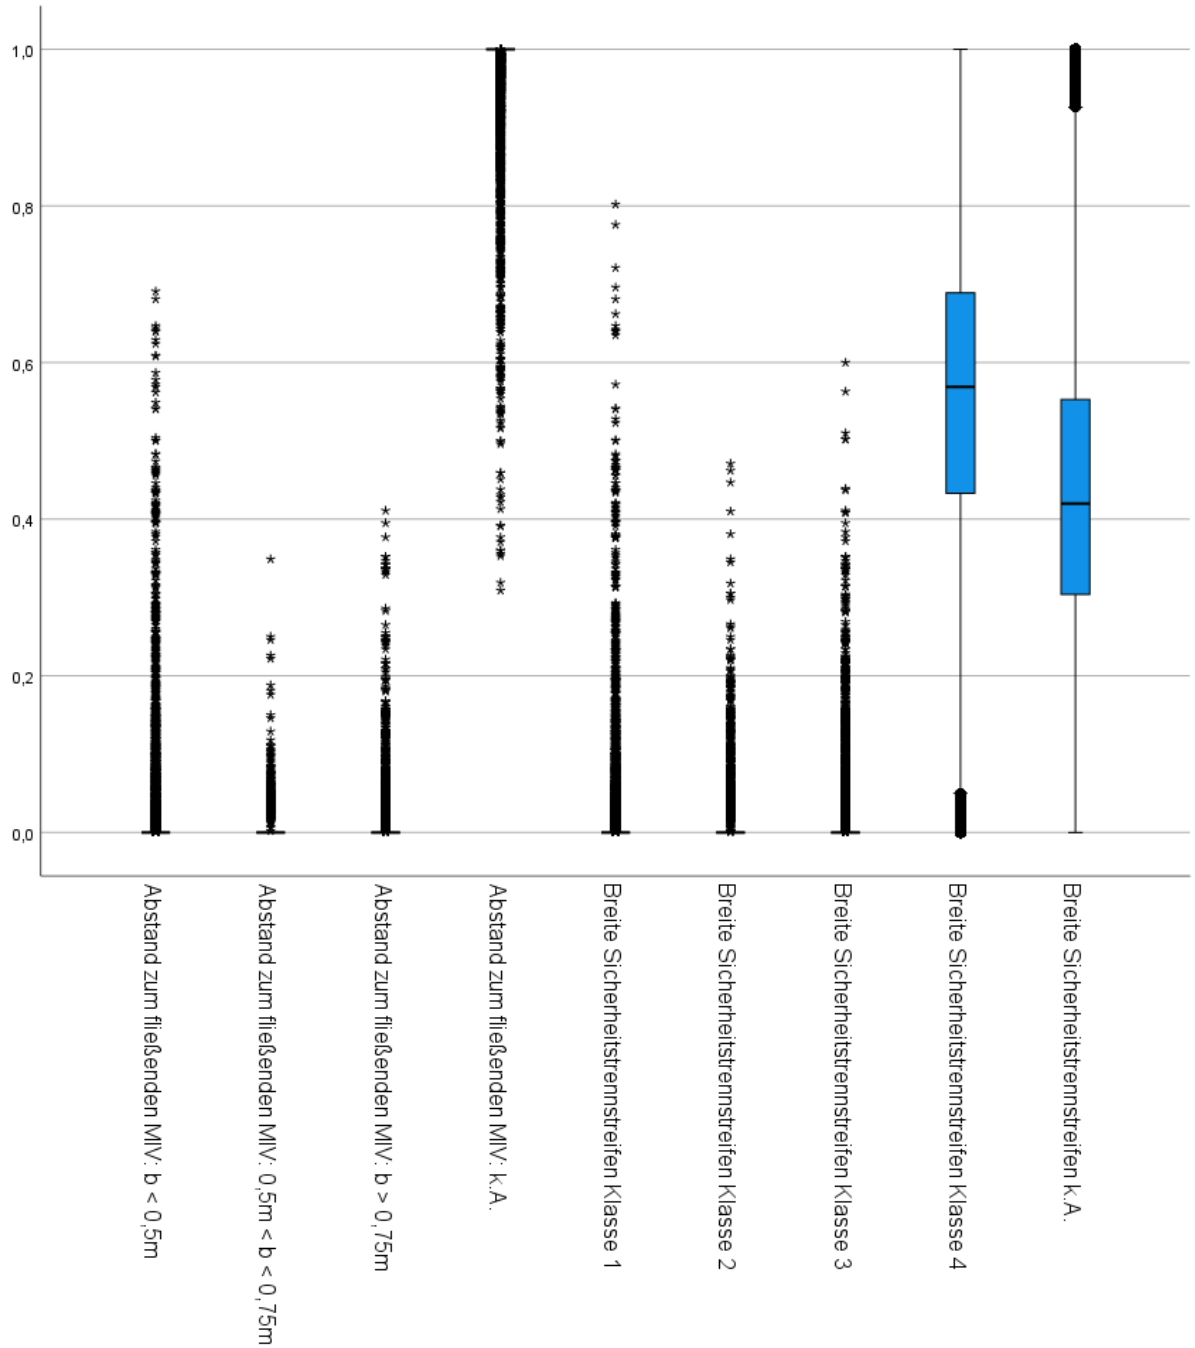


Abbildung 91: Verteilung Sicherheitsraum

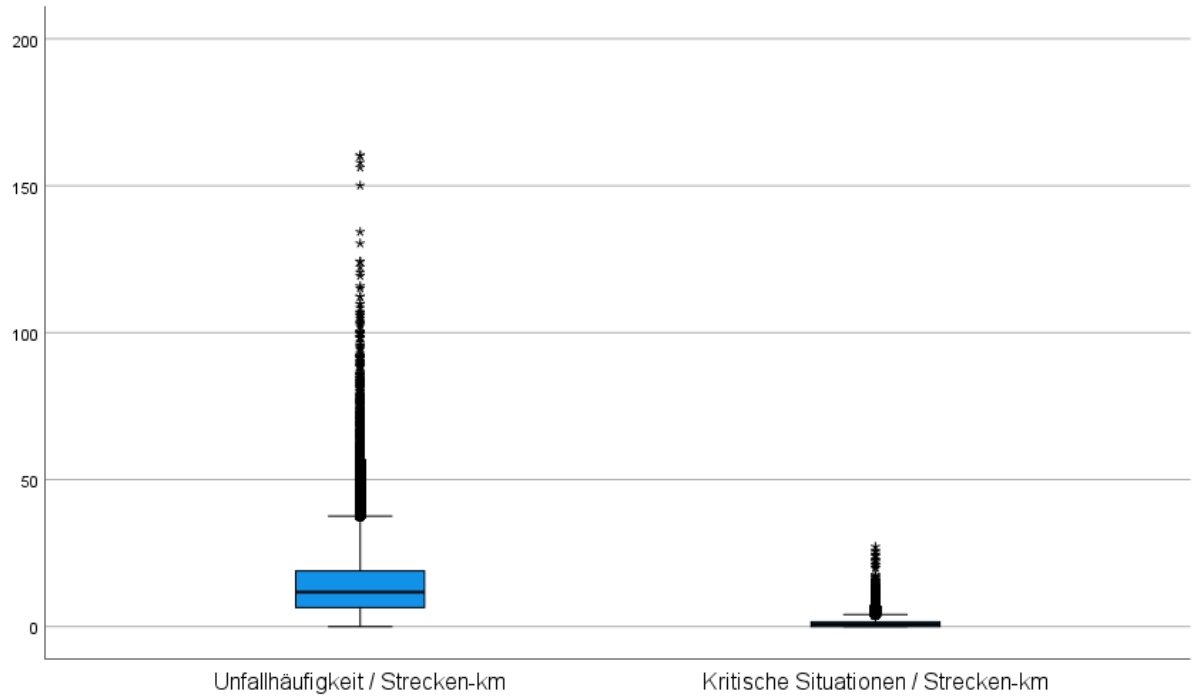


Abbildung 92: Verteilung objektiven und subjektiven Sicherheit an Strecken

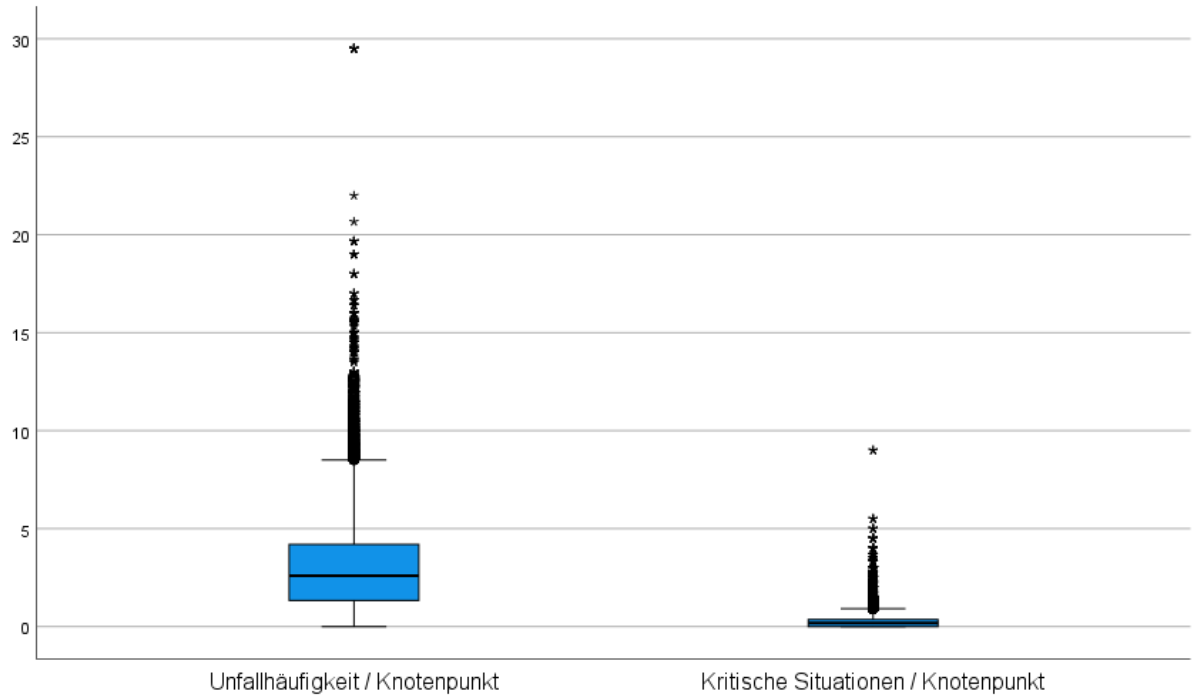


Abbildung 93: Verteilung objektiven und subjektiven Sicherheit an Knotenpunkten

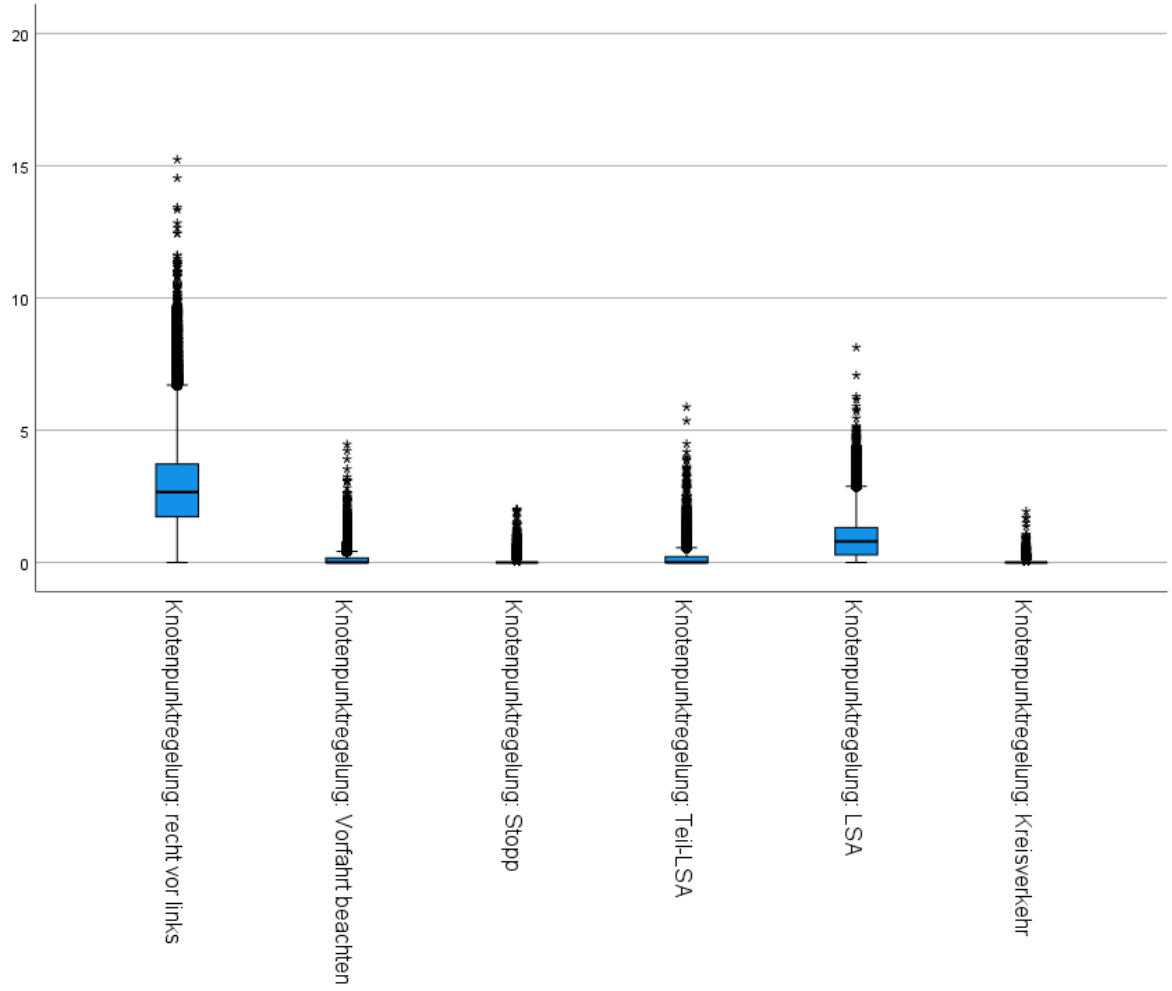


Abbildung 94: Verteilung der Knotenpunkte und ihrer Regelungsart

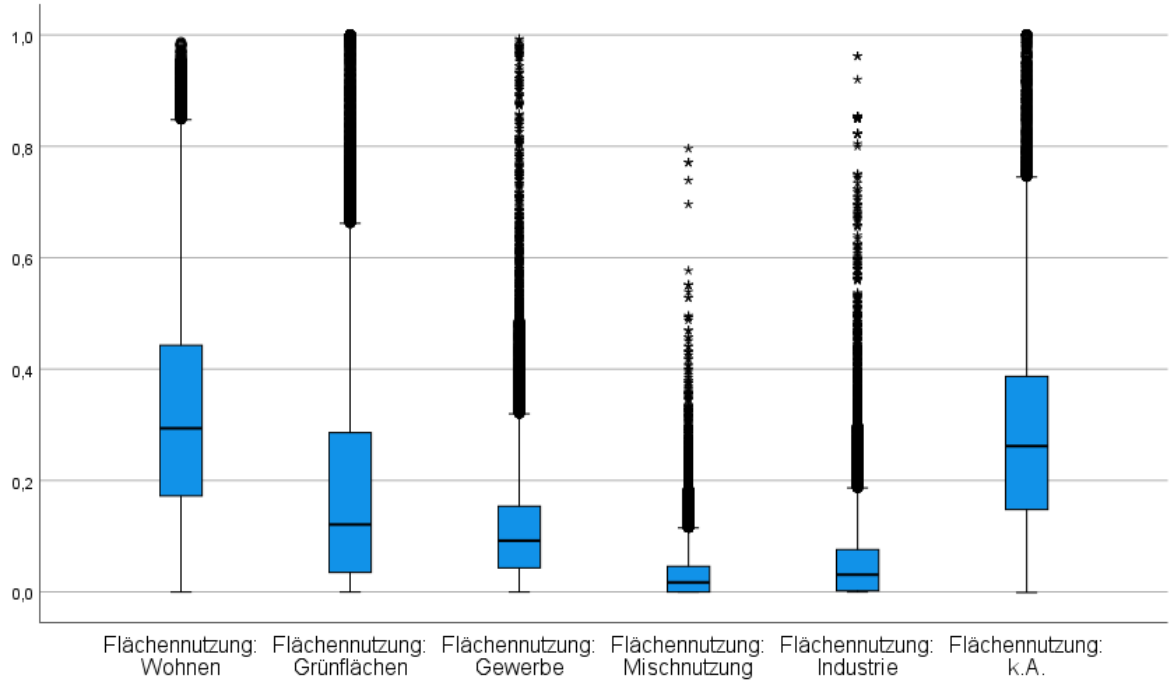


Abbildung 95: Verteilung objektiven und subjektiven Sicherheit an Knotenpunkten

# Anhang 6

| Einflussfaktor | Variable | Aggregierte Variable | |
|---|---|---|---|
| Reiseweite | Distanz | 1 | Fahrtweite |
| Reisezeit | Reisezeit | 2 | Reisezeit |
| Längsneigung | Durchschnittliche Längsneigung | 3 | Durchschnittliche Längsneigung |
| | Maximal Längsneigung | 4 | Maximal Längsneigung |
| | Längsneigung < 2% | 5 | Längsneigung <2% |
| | Längsneigung von 2-4% | 6 | Längsneigung >2% |
| | Längsneigung > 4% | | |
| | Längsneigung < 0% (Gefälle) | | |
| Fahrbahnoberfläche | Asphalt | 7 | Asphaltoberfläche |
| | Pflaster | | |
| | Kopfsteinpflaster | 8 | Kopfsteinpflaster |
| | Natur, gebunden (Schotter) | | |
| | Natur, ungebunden (Waldboden) | | |
| | keine Angabe zur Oberfläche | | |
| Objektive Sicherheit | Unfallhäufigkeit gesamt | 9 | Sicherheit (Unfallhäufigkeit) |
| Subjektive Sicherheit | Häufigkeit kritischer Situationen gesamt | 10 | Kritische Situationen |
| Radverkehrsführungsform | Mischverkehr | 12 | keine Radinfrastr. Vorhanden |
| | Mischverkehr mit Schutzstreifen | 11 | Radinfrastruktur vorhanden |
| | Radfahrstreifen | | |
| | Bussonderfahrstreifen mit Freigabe für den Radverkehr | | |
| | Radweg | | |
| | Gemeinsamer Geh- und Radweg | | |
| | Selbstständige gemeinsame Geh- und Radwege | | |
| | Selbstständige getrennte Geh- und Radwege | | |
| | Selbstständige Gehwege (auch FGZ) | | |
| | keine Angabe zur Radverkehrsführungsform | 12 | keine Radinfrastr. Vorhanden |
| Breite Radverkehrsführung | Breite der Radverkehrsführung <1,5m | 13 | Breite Radinfrastruktur < 1,5m |
| | Breite der Radverkehrsführung zw. 1,5-2,0m | 14 | Breite Radinfrastruktur > 1,5m |
| | Breite der Radverkehrsführung zw. >2,0m | | |
| | keine Angabe zur Breite der Radverkehrsführung | | |
| DTV des Kfz-Verkehrs | Durchschnittlicher DTV des Kfz-Verkehrs entlang einer Route | 15 | Mittlerer DTV des Kfz-Verkehrs |
| | DTV ≤ 5.000Kfz/Tag | | |
| | 5.000 < DTV ≤ 10.000 Kfz/Tag | | |
| | DTV > 10.000 Kfz/Tag | | |
| | keine Angabe zum DTV | | |
| Max. Zulässige Geschwindigkeit des MIV | v ≤ 6km/h | 16 | Max. zul. Geschw. Kfz < 30km/h |
| | 6km/h < v ≤ 30km/h | | |
| | 31km/h < v ≤ 50km/h | 17 | Max. zul. Geschw. Kfz > 30km/h |
| | v > 50km/h | | |
| | keine Angabe | | |
| Ruhender Verkehr | Längs | 18 | Ruhender Verkehr (längs) |
| | Schräg | | |
| | Senkrecht | | |
| | Kombination | | |
| | Keine Angabe oder nicht vorhanden | 19 | k.A. zum ruhenden Verkehr |
| Knotenpunkte und Art der Regelung | Regelung „Recht-Vor-Links“ (RVL) | 20 | KP-Regelung: recht vor links |
| | Regelung durch Verkehrszeichen 205 | | |
| | Regelung durch Verkehrszeichen 206 | | |
| | Regelung durch Teil-LSA | | |
| | Regelung durch LSA | 21 | KP-Regelung: LSA |
| | keine Angabe zur Art der Regelung | | |
| DTV Rad | Durchschnittlicher DTV des Radverkehrs | 22 | Mittlerer DTV-Rad |
| | DTV ≤ 500Rad/Tag | 23 | DTV-Rad < 500 |
| | 500 < DTV ≤ 1.000Rad/Tag | 24 | DTV-Rad > 500 |
| | 1.000 < DTV ≤ 1.500Rad/Tag | | |
| | 1.500 < DTV ≤ 2.000Rad/Tag | | |
| | 2.000 < DTV ≤ 2.500Rad/Tag | | |
| | DTV > 2.500Rad/Tag | | |
| | Keine Angabe zum DTV | | |
| Umfeldnutzung | Wohngebietsflächen | 25 | Wohngebietsflächen |
| | Grünflächen | 26 | Grünflächen |
| | Gewerbeflächen | | |
| | Mischnutzung | | |
| | Industrie | | |
| | Sonstige oder keine Angabe | | |
| Anzahl der Fahrstreifen MIV | 1 Fahrstreifen | 27 | 1 Fahrtstreifen Kfz-Verkehr |
| | 2 Fahrstreifen | 28 | > 1 Fahrstreifen Kfz-Verkehr |
| | >2 Fahrstreifen | | |
| | Keine Angabe zur Anzahl der Fahrstreifen | | |

Originäre Variablen
aggregierte Variable/n
Ausschluss aufgrund von a) zu kleinem N, b) fehlender Information, c) zu vielen Ausreißern oder d) nicht relevant

Abbildung 96: Aggregationsschlüssel der unabhängigen Variablen

# Anhang 7

| | | dist | rz | LN_avg | LN_max | LN_kl2prz | LN_gr2prz | OF_Asph | OF_Kopf | UFH | HKS | RadInf | kRadInf | Breite_RadInf_kl1,5m |
|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|
| dist | Pearson-Korrelation | 1 | 0,807 | 0,081 | 0,448 | -0,043 | 0,017 | 0,061 | -0,032 | -0,150 | -0,118 | 0,193 | -0,193 | -0,179 |
| | Sig. (2-seitig) | | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| | N | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| rz | Pearson-Korrelation | 0,807 | 1 | 0,143 | 0,481 | -0,070 | 0,051 | -0,189 | 0,057 | -0,158 | -0,123 | -0,022 | 0,021 | -0,002 |
| | Sig. (2-seitig) | 0,000 | | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,615 |
| | N | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| LN_avg | Pearson-Korrelation | 0,081 | 0,143 | 1 | 0,646 | -0,530 | 0,798 | -0,254 | -0,061 | -0,353 | -0,180 | -0,236 | 0,232 | 0,194 |
| | Sig. (2-seitig) | 0,000 | 0,000 | | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| | N | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| LN_max | Pearson-Korrelation | 0,448 | 0,481 | 0,646 | 1 | -0,298 | 0,423 | -0,197 | -0,025 | -0,289 | -0,196 | -0,093 | 0,091 | 0,068 |
| | Sig. (2-seitig) | 0,000 | 0,000 | 0,000 | | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| | N | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| LN_kl2prz | Pearson-Korrelation | -0,043 | -0,070 | -0,530 | -0,298 | 1 | -0,330 | 0,173 | -0,004 | 0,231 | 0,086 | 0,131 | -0,128 | -0,097 |
| | Sig. (2-seitig) | 0,000 | 0,000 | 0,000 | 0,000 | | 0,000 | 0,000 | 0,320 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| | N | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| LN_gr2prz | Pearson-Korrelation | 0,017 | 0,051 | 0,798 | 0,423 | -0,330 | 1 | -0,172 | -0,062 | -0,312 | -0,136 | -0,214 | 0,211 | 0,178 |
| | Sig. (2-seitig) | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| | N | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| OF_Asph | Pearson-Korrelation | 0,061 | -0,189 | -0,254 | -0,197 | 0,173 | -0,172 | 1 | -0,220 | 0,196 | 0,111 | 0,353 | -0,353 | -0,252 |
| | Sig. (2-seitig) | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| | N | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| OF_Kopf | Pearson-Korrelation | -0,032 | 0,057 | -0,061 | -0,025 | -0,004 | -0,062 | -0,220 | 1 | 0,051 | 0,099 | -0,099 | 0,097 | 0,057 |
| | Sig. (2-seitig) | 0,000 | 0,000 | 0,000 | 0,000 | 0,320 | 0,000 | 0,000 | | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| | N | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| UFH | Pearson-Korrelation | -0,150 | -0,158 | -0,353 | -0,289 | 0,231 | -0,312 | 0,196 | 0,051 | 1 | 0,562 | 0,240 | -0,238 | -0,192 |
| | Sig. (2-seitig) | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | | 0,000 | 0,000 | 0,000 | 0,000 |
| | N | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| HKS | Pearson-Korrelation | -0,118 | -0,123 | -0,180 | -0,196 | 0,086 | -0,136 | 0,111 | 0,099 | 0,562 | 1 | 0,278 | -0,277 | -0,194 |
| | Sig. (2-seitig) | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | | 0,000 | 0,000 | 0,000 |
| | N | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| RadInf | Pearson-Korrelation | 0,193 | -0,022 | -0,236 | -0,093 | 0,131 | -0,214 | 0,353 | -0,099 | 0,240 | 0,278 | 1 | -0,999 | -0,811 |
| | Sig. (2-seitig) | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | | 0,000 | 0,000 |
| | N | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| kRadInf | Pearson-Korrelation | -0,193 | 0,021 | 0,232 | 0,091 | -0,128 | 0,211 | -0,353 | 0,097 | -0,238 | -0,277 | -0,999 | 1 | 0,810 |
| | Sig. (2-seitig) | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | | 0,000 |
| | N | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| Breite_RadInf_kl1,5m2 | Pearson-Korrelation | -0,179 | -0,002 | 0,194 | 0,068 | -0,097 | 0,178 | -0,252 | 0,057 | -0,192 | -0,194 | -0,811 | 0,810 | 1 |
| | Sig. (2-seitig) | 0,000 | 0,615 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | |
| | N | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| Breite_RadInf_gr1,5m | Pearson-Korrelation | 0,179 | 0,002 | -0,194 | -0,068 | 0,097 | -0,178 | 0,252 | -0,057 | 0,192 | 0,194 | 0,811 | -0,810 | -1,000 |
| | Sig. (2-seitig) | 0,000 | 0,614 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| | N | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| DTV-MIV_avg | Pearson-Korrelation | 0,140 | 0,143 | -0,037 | 0,071 | -0,020 | -0,066 | -0,042 | -0,049 | 0,254 | 0,270 | 0,319 | -0,318 | -0,313 |
| | Sig. (2-seitig) | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| | N | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| v_zul-MIV_kl30kmh | Pearson-Korrelation | -0,234 | -0,201 | -0,051 | -0,172 | 0,047 | -0,009 | 0,048 | 0,034 | -0,029 | -0,085 | -0,446 | 0,446 | 0,382 |
| | Sig. (2-seitig) | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,027 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| | N | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| v_zul-MIV_gr30kmh | Pearson-Korrelation | 0,095 | -0,018 | -0,197 | -0,116 | 0,114 | -0,136 | 0,214 | -0,041 | 0,276 | 0,163 | 0,188 | -0,186 | -0,198 |
| | Sig. (2-seitig) | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| | N | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| RV_laengs | Pearson-Korrelation | -0,201 | -0,200 | -0,203 | -0,236 | 0,154 | -0,125 | 0,390 | 0,082 | 0,221 | 0,071 | -0,277 | 0,277 | 0,262 |
| | Sig. (2-seitig) | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| | N | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| RV_kein | Pearson-Korrelation | 0,209 | 0,206 | 0,227 | 0,259 | -0,160 | 0,143 | -0,410 | -0,092 | -0,243 | -0,081 | 0,277 | -0,276 | -0,258 |
| | Sig. (2-seitig) | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| | N | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| KP_rvl | Pearson-Korrelation | -0,196 | -0,208 | -0,249 | -0,270 | 0,188 | -0,180 | 0,314 | 0,119 | 0,330 | 0,038 | -0,245 | 0,244 | 0,231 |
| | Sig. (2-seitig) | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| | N | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| KP_LSA | Pearson-Korrelation | 0,015 | -0,016 | -0,215 | -0,151 | 0,122 | -0,173 | 0,023 | -0,009 | 0,492 | 0,444 | 0,316 | -0,314 | -0,298 |
| | Sig. (2-seitig) | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,038 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| | N | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| DTV-Rad_avg | Pearson-Korrelation | 0,144 | -0,092 | -0,251 | -0,132 | 0,125 | -0,230 | 0,484 | 0,029 | 0,368 | 0,311 | 0,678 | -0,677 | -0,520 |
| | Sig. (2-seitig) | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| | N | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| DTV-Rad_kl500 | Pearson-Korrelation | -0,083 | 0,130 | 0,276 | 0,166 | -0,145 | 0,246 | -0,462 | -0,026 | -0,525 | -0,430 | -0,618 | 0,616 | 0,528 |
| | Sig. (2-seitig) | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| | N | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| DTV-Rad_gr500 | Pearson-Korrelation | 0,083 | -0,130 | -0,276 | -0,166 | 0,145 | -0,246 | 0,462 | 0,026 | 0,525 | 0,430 | 0,618 | -0,616 | -0,528 |
| | Sig. (2-seitig) | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| | N | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| FN_gruen | Pearson-Korrelation | 0,250 | 0,225 | 0,271 | 0,298 | -0,149 | 0,194 | -0,093 | -0,122 | -0,398 | -0,291 | 0,152 | -0,152 | -0,146 |
| | Sig. (2-seitig) | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| | N | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| FN_wohn | Pearson-Korrelation | -0,217 | -0,226 | -0,063 | -0,194 | 0,080 | -0,005 | 0,110 | -0,045 | -0,004 | -0,142 | -0,376 | 0,375 | 0,318 |
| | Sig. (2-seitig) | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,218 | 0,000 | 0,000 | 0,295 | 0,000 | 0,000 | 0,000 | 0,000 |
| | N | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| FS_1 | Pearson-Korrelation | -0,073 | -0,164 | -0,159 | -0,149 | 0,131 | -0,080 | 0,556 | 0,138 | 0,155 | -0,039 | -0,175 | 0,176 | 0,144 |
| | Sig. (2-seitig) | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| | N | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| FS_gr1 | Pearson-Korrelation | 0,043 | 0,003 | -0,121 | -0,086 | 0,012 | -0,104 | 0,050 | -0,038 | 0,309 | 0,429 | 0,439 | -0,437 | -0,353 |
| | Sig. (2-seitig) | 0,000 | 0,439 | 0,000 | 0,000 | 0,003 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| | N | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |

Abbildung 97: Korrelationsmatrix der unabhängigen Variablen (Teil 1)

| Breite_RadInf_gr1,5m | DTV-MIV_avg | v_zul-MIV_kl30kmh | v_zul-MIV_gr30kmh | RV_laengs | RV_kein | KP_rvl | KP_LSA | DTV-Rad_avg | DTV-Rad_kl500 | DTV-Rad_gr500 | FN_gruen | FN_wohn | FS_1 | FS_gr1 |
|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|
| 0,179 | 0,140 | -0,234 | 0,095 | -0,201 | 0,209 | -0,196 | 0,015 | 0,144 | -0,083 | 0,083 | 0,250 | -0,217 | -0,073 | 0,043 |
| 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| 0,002 | 0,143 | -0,201 | -0,018 | -0,200 | 0,206 | -0,208 | -0,016 | -0,092 | 0,130 | -0,130 | 0,225 | -0,226 | -0,164 | 0,003 |
| 0,614 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,439 |
| 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| -0,194 | -0,037 | -0,051 | -0,197 | -0,203 | 0,227 | -0,249 | -0,215 | -0,251 | 0,276 | -0,276 | 0,271 | -0,063 | -0,159 | -0,121 |
| 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| -0,068 | 0,071 | -0,172 | -0,116 | -0,236 | 0,259 | -0,270 | -0,151 | -0,132 | 0,166 | -0,166 | 0,298 | -0,194 | -0,149 | -0,086 |
| 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| 0,097 | -0,020 | 0,047 | 0,114 | 0,154 | -0,160 | 0,188 | 0,122 | 0,125 | -0,145 | 0,145 | -0,149 | 0,080 | 0,131 | 0,012 |
| 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,003 |
| 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| -0,178 | -0,066 | -0,009 | -0,136 | -0,125 | 0,143 | -0,180 | -0,173 | -0,230 | 0,246 | -0,246 | 0,194 | -0,005 | -0,080 | -0,104 |
| 0,000 | 0,000 | 0,027 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,218 | 0,000 | 0,000 |
| 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| 0,252 | -0,042 | 0,048 | 0,214 | 0,390 | -0,410 | 0,314 | 0,023 | 0,484 | -0,462 | 0,462 | -0,093 | 0,110 | 0,556 | 0,050 |
| 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| -0,057 | -0,049 | 0,034 | -0,041 | 0,082 | -0,092 | 0,119 | -0,009 | 0,029 | -0,026 | 0,026 | -0,122 | -0,045 | 0,138 | -0,038 |
| 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,038 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| 0,192 | 0,254 | -0,029 | 0,276 | 0,221 | -0,243 | 0,330 | 0,492 | 0,368 | -0,525 | 0,525 | -0,398 | -0,004 | 0,155 | 0,309 |
| 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,295 | 0,000 | 0,000 |
| 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| 0,194 | 0,270 | -0,085 | 0,163 | 0,071 | -0,081 | 0,038 | 0,444 | 0,311 | -0,430 | 0,430 | -0,291 | -0,142 | -0,039 | 0,429 |
| 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| 0,811 | 0,319 | -0,446 | 0,188 | -0,277 | 0,277 | -0,245 | 0,316 | 0,678 | -0,618 | 0,618 | 0,152 | -0,376 | -0,175 | 0,439 |
| 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| -0,810 | -0,318 | 0,446 | -0,186 | 0,277 | -0,276 | 0,244 | -0,314 | -0,677 | 0,616 | -0,616 | -0,152 | 0,375 | 0,176 | -0,437 |
| 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| -1,000 | -0,313 | 0,382 | -0,198 | 0,262 | -0,258 | 0,231 | -0,298 | -0,520 | 0,528 | -0,528 | -0,146 | 0,318 | 0,144 | -0,353 |
| 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| 1 | 0,313 | -0,382 | 0,198 | -0,262 | 0,258 | -0,231 | 0,298 | 0,520 | -0,528 | 0,528 | 0,146 | -0,318 | -0,144 | 0,353 |
| | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| 0,313 | 1 | -0,386 | 0,407 | -0,252 | 0,264 | -0,244 | 0,447 | 0,057 | -0,198 | 0,198 | -0,165 | -0,239 | -0,172 | 0,671 |
| 0,000 | | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| -0,382 | -0,386 | 1 | -0,456 | 0,439 | -0,463 | 0,497 | -0,326 | -0,228 | 0,215 | -0,215 | -0,257 | 0,572 | 0,257 | -0,292 |
| 0,000 | 0,000 | | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| 0,198 | 0,407 | -0,456 | 1 | 0,038 | -0,026 | 0,041 | 0,517 | 0,094 | -0,284 | 0,284 | -0,349 | -0,025 | 0,268 | 0,314 |
| 0,000 | 0,000 | 0,000 | | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| -0,262 | -0,252 | 0,439 | 0,038 | 1 | -0,965 | 0,584 | -0,098 | -0,063 | -0,036 | 0,036 | -0,377 | 0,441 | 0,626 | -0,179 |
| 0,000 | 0,000 | 0,000 | 0,000 | | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| 0,258 | 0,264 | -0,463 | -0,026 | -0,965 | 1 | -0,607 | 0,096 | 0,061 | 0,036 | -0,036 | 0,385 | -0,432 | -0,650 | 0,188 |
| 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| -0,231 | -0,244 | 0,497 | 0,041 | 0,584 | -0,607 | 1 | -0,118 | -0,053 | -0,046 | 0,046 | -0,414 | 0,521 | 0,545 | -0,190 |
| 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| 0,298 | 0,447 | -0,326 | 0,517 | -0,098 | 0,096 | -0,118 | 1 | 0,243 | -0,427 | 0,427 | -0,309 | -0,194 | -0,055 | 0,476 |
| 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| 0,520 | 0,057 | -0,228 | 0,094 | -0,063 | 0,061 | -0,053 | 0,243 | 1 | -0,816 | 0,816 | 0,103 | -0,285 | -0,042 | 0,171 |
| 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| -0,528 | -0,198 | 0,215 | -0,284 | -0,036 | 0,036 | -0,046 | -0,427 | -0,816 | 1 | -1,000 | 0,091 | 0,241 | -0,113 | -0,287 |
| 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |
| 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| 0,528 | 0,198 | -0,215 | 0,284 | 0,036 | -0,036 | 0,046 | 0,427 | 0,816 | -1,000 | 1 | -0,091 | -0,241 | 0,113 | 0,287 |
| 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | | 0,000 | 0,000 | 0,000 | 0,000 |
| 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| 0,146 | -0,165 | -0,257 | -0,349 | -0,377 | 0,385 | -0,414 | -0,309 | 0,103 | 0,091 | -0,091 | 1 | -0,397 | -0,339 | -0,199 |
| 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | | 0,000 | 0,000 | 0,000 |
| 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| -0,318 | -0,239 | 0,572 | -0,025 | 0,441 | -0,432 | 0,521 | -0,194 | -0,285 | 0,241 | -0,241 | -0,397 | 1 | 0,328 | -0,257 |
| 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | | 0,000 | 0,000 |
| 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| -0,144 | -0,172 | 0,257 | 0,268 | 0,626 | -0,650 | 0,545 | -0,055 | -0,042 | -0,113 | 0,113 | -0,339 | 0,328 | 1 | -0,364 |
| 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | | 0,000 |
| 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |
| 0,353 | 0,671 | -0,292 | 0,314 | -0,179 | 0,188 | -0,190 | 0,476 | 0,171 | -0,287 | 0,287 | -0,199 | -0,257 | -0,364 | 1 |
| 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | |
| 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 | 55377 |

Abbildung 98: Korrelationsmatrix der unabhängigen Variablen (Teil 2)

# Anhang 8

| | Chi-Quadrat-Tabelle | | | | | | | | | | | | | | |
|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|
| α / FG | 0,99 | 0,975 | 0,95 | 0,9 | 0,8 | 0,7 | 0,5 | 0,3 | 0,2 | 0,1 | 0,05 | 0,025 | 0,01 | 0,001 | 0,0001 |
| 1 | 0,00016 | 0,00098 | 0,00393 | 0,0158 | 0,064 | 0,148 | 0,455 | 1,07 | 1,64 | 2,71 | 3,84 | 5,02 | 6,63 | 10,83 | 15,14 |
| 2 | 0,0201 | 0,0506 | 0,1026 | 0,2107 | 0,446 | 0,713 | 1,39 | 2,41 | 3,22 | 4,61 | 5,99 | 7,38 | 9,21 | 13,82 | 18,42 |
| 3 | 0,115 | 0,216 | 0,352 | 0,584 | 1,01 | 1,42 | 2,37 | 3,66 | 4,64 | 6,25 | 7,81 | 9,35 | 11,34 | 16,27 | 21,11 |
| 4 | 0,297 | 0,484 | 0,711 | 1,06 | 1,65 | 2,19 | 3,36 | 4,88 | 5,99 | 7,78 | 9,49 | 11,14 | 13,28 | 18,47 | 23,51 |
| 5 | 0,554 | 0,831 | 1,15 | 1,61 | 2,34 | 3,00 | 4,35 | 6,06 | 7,29 | 9,24 | 11,07 | 12,83 | 15,09 | 20,52 | 25,74 |
| 6 | 0,872 | 1,24 | 1,64 | 2,20 | 3,07 | 3,83 | 5,35 | 7,23 | 8,56 | 10,64 | 12,59 | 14,45 | 16,81 | 22,46 | 27,86 |
| 7 | 1,24 | 1,69 | 2,17 | 2,83 | 3,82 | 4,67 | 6,35 | 8,38 | 9,80 | 12,02 | 14,07 | 16,01 | 18,48 | 24,32 | 29,88 |
| 8 | 1,65 | 2,18 | 2,73 | 3,49 | 4,59 | 5,53 | 7,34 | 9,52 | 11,03 | 13,36 | 15,51 | 17,53 | 20,09 | 26,12 | 31,83 |
| 9 | 2,09 | 2,70 | 3,33 | 4,17 | 5,38 | 6,39 | 8,34 | 10,66 | 12,24 | 14,68 | 16,92 | 19,02 | 21,67 | 27,88 | 33,72 |
| 10 | 2,56 | 3,25 | 3,94 | 4,87 | 6,18 | 7,27 | 9,34 | 11,78 | 13,44 | 15,99 | 18,31 | 20,48 | 23,21 | 29,59 | 35,56 |
| 11 | 3,05 | 3,82 | 4,57 | 5,58 | 6,99 | 8,15 | 10,34 | 12,90 | 14,63 | 17,28 | 19,68 | 21,92 | 24,72 | 31,26 | 37,37 |
| 12 | 3,57 | 4,40 | 5,23 | 6,30 | 7,81 | 9,03 | 11,34 | 14,01 | 15,81 | 18,55 | 21,03 | 23,34 | 26,22 | 32,91 | 39,13 |
| 13 | 4,11 | 5,01 | 5,89 | 7,04 | 8,63 | 9,93 | 12,34 | 15,12 | 16,98 | 19,81 | 22,36 | 24,74 | 27,69 | 34,53 | 40,87 |
| 14 | 4,66 | 5,63 | 6,57 | 7,79 | 9,47 | 10,82 | 13,34 | 16,22 | 18,15 | 21,06 | 23,68 | 26,12 | 29,14 | 36,12 | 42,58 |
| 15 | 5,23 | 6,26 | 7,26 | 8,55 | 10,31 | 11,72 | 14,34 | 17,32 | 19,31 | 22,31 | 25,00 | 27,49 | 30,58 | 37,70 | 44,26 |
| 16 | 5,81 | 6,91 | 7,96 | 9,31 | 11,15 | 12,62 | 15,34 | 18,42 | 20,47 | 23,54 | 26,30 | 28,85 | 32,00 | 39,25 | 45,92 |
| 17 | 6,41 | 7,56 | 8,67 | 10,09 | 12,00 | 13,53 | 16,34 | 19,51 | 21,61 | 24,77 | 27,59 | 30,19 | 33,41 | 40,79 | 47,57 |
| 18 | 7,01 | 8,23 | 9,39 | 10,86 | 12,86 | 14,44 | 17,34 | 20,60 | 22,76 | 25,99 | 28,87 | 31,53 | 34,81 | 42,31 | 49,19 |
| 19 | 7,63 | 8,91 | 10,12 | 11,65 | 13,72 | 15,35 | 18,34 | 21,69 | 23,90 | 27,20 | 30,14 | 32,85 | 36,19 | 43,82 | 50,80 |
| 20 | 8,26 | 9,59 | 10,85 | 12,44 | 14,58 | 16,27 | 19,34 | 22,77 | 25,04 | 28,41 | 31,41 | 34,17 | 37,57 | 45,31 | 52,39 |
| 21 | 8,90 | 10,28 | 11,59 | 13,24 | 15,44 | 17,18 | 20,34 | 23,86 | 26,17 | 29,62 | 32,67 | 35,48 | 38,93 | 46,80 | 53,96 |
| 22 | 9,54 | 10,98 | 12,34 | 14,04 | 16,31 | 18,10 | 21,34 | 24,94 | 27,30 | 30,81 | 33,92 | 36,78 | 40,29 | 48,27 | 55,52 |
| 23 | 10,20 | 11,69 | 13,09 | 14,85 | 17,19 | 19,02 | 22,34 | 26,02 | 28,43 | 32,01 | 35,17 | 38,08 | 41,64 | 49,73 | 57,07 |
| 24 | 10,86 | 12,40 | 13,85 | 15,66 | 18,06 | 19,94 | 23,34 | 27,10 | 29,55 | 33,20 | 36,42 | 39,36 | 42,98 | 51,18 | 58,61 |
| 25 | 11,52 | 13,12 | 14,61 | 16,47 | 18,94 | 20,87 | 24,34 | 28,17 | 30,68 | 34,38 | 37,65 | 40,65 | 44,31 | 52,62 | 60,14 |
| 26 | 12,20 | 13,84 | 15,38 | 17,29 | 19,82 | 21,79 | 25,34 | 29,25 | 31,79 | 35,56 | 38,89 | 41,92 | 45,64 | 54,05 | 61,66 |
| 27 | 12,88 | 14,57 | 16,15 | 18,11 | 20,70 | 22,72 | 26,34 | 30,32 | 32,91 | 36,74 | 40,11 | 43,19 | 46,96 | 55,48 | 63,16 |
| 28 | 13,56 | 15,31 | 16,93 | 18,94 | 21,59 | 23,65 | 27,34 | 31,39 | 34,03 | 37,92 | 41,34 | 44,46 | 48,28 | 56,89 | 64,66 |
| 29 | 14,26 | 16,05 | 17,71 | 19,77 | 22,48 | 24,58 | 28,34 | 32,46 | 35,14 | 39,09 | 42,56 | 45,72 | 49,59 | 58,30 | 66,15 |
| 30 | 14,95 | 16,79 | 18,49 | 20,60 | 23,36 | 25,51 | 29,34 | 33,53 | 36,25 | 40,26 | 43,77 | 46,98 | 50,89 | 59,70 | 67,63 |
| 35 | 18,51 | 20,57 | 22,47 | 24,80 | 27,84 | 30,18 | 34,34 | 38,86 | 41,78 | 46,06 | 49,80 | 53,20 | 57,34 | 66,62 | 74,93 |
| 40 | 22,16 | 24,43 | 26,51 | 29,05 | 32,34 | 34,87 | 39,34 | 44,16 | 47,27 | 51,81 | 55,76 | 59,34 | 63,69 | 73,40 | 82,06 |
| 50 | 29,71 | 32,36 | 34,76 | 37,69 | 41,45 | 44,31 | 49,33 | 54,72 | 58,16 | 63,17 | 67,50 | 71,42 | 76,15 | 86,66 | 95,97 |
| 60 | 37,48 | 40,48 | 43,19 | 46,46 | 50,64 | 53,81 | 59,33 | 65,23 | 68,97 | 74,40 | 79,08 | 83,30 | 88,38 | 99,61 | 109,50 |
| 80 | 53,54 | 57,15 | 60,39 | 64,28 | 69,21 | 72,92 | 79,33 | 86,12 | 90,41 | 96,58 | 101,88 | 106,63 | 112,33 | 124,84 | 135,78 |
| 100 | 70,06 | 74,22 | 77,93 | 82,36 | 87,95 | 92,13 | 99,33 | 106,91 | 111,67 | 118,50 | 124,34 | 129,56 | 135,81 | 149,45 | 161,32 |
| 120 | 86,92 | 91,57 | 95,70 | 100,62 | 106,81 | 111,42 | 119,33 | 127,62 | 132,81 | 140,23 | 146,57 | 152,21 | 158,95 | 173,62 | 186,33 |
| 150 | 112,67 | 117,98 | 122,69 | 128,28 | 135,26 | 140,46 | 149,33 | 158,58 | 164,35 | 172,58 | 179,58 | 185,80 | 193,21 | 209,26 | 223,11 |
| 200 | 156,43 | 162,73 | 168,28 | 174,84 | 183,00 | 189,05 | 199,33 | 209,99 | 216,61 | 226,02 | 233,99 | 241,06 | 249,45 | 267,54 | 283,06 |

α = Zahl der erklärenden Variablen (J)
FG = Zahl der Freiheitsgrade (DR)

Abbildung 99: Chi-Quadrat-Tabelle